


Programming Hive



Hive



编程指南



[美] *Edward Capriolo*
 Dean Wampler
 Jason Rutberglen 著
 曹坤 译

O'REILLY®

人民邮电出版社
POSTS & TELECOM PRESS

目 录

[版权信息](#)

[版权声明](#)

[内容提要](#)

[O'Reilly Media, Inc.介绍](#)

[作者简介](#)

[作者序](#)

[致谢](#)

[前言](#)

[第1章 基础知识](#)

[1.1 Hadoop和MapReduce综述](#)

[MapReduce](#)

[1.2 Hadoop生态系统中的Hive](#)

[1.2.1 Pig](#)

[1.2.2 HBase](#)

[1.2.3 Cascading、Crunch及其他](#)

[1.3 Java和Hive: 词频统计算法](#)

[1.4 后续事情](#)

[第2章 基础操作](#)

[2.1 安装预先配置好的虚拟机](#)

[2.2 安装详细步骤](#)

[2.2.1 装Java](#)

[2.2.2 安装Hadoop](#)

[2.2.3 本地模式、伪分布式模式和分布式模式](#)

[2.2.4 测试Hadoop](#)

[2.2.5 安装Hive](#)

[2.3 Hive内部是什么](#)

[2.4 启动Hive](#)

[2.5 配置Hadoop环境](#)

[2.5.1 本地模式配置](#)

[2.5.2 分布式模式和伪分布式模式配置](#)

[2.5.3 使用JDBC连接元数据](#)

[2.6 Hive命令](#)

[命令选项](#)

[2.7 命令行界面](#)
[2.7.1 CLI 选项](#)
[2.7.2 变量和属性](#)
[2.7.3 Hive中“一次使用”命令](#)
[2.7.4 从文件中执行Hive查询](#)
[2.7.5 hiverc文件](#)
[2.7.6 使用Hive CLI的更多介绍](#)
[2.7.7 查看操作命令历史](#)
[2.7.8 执行shell命令](#)
[2.7.9 在Hive内使用Hadoop的dfs命令](#)
[2.7.10 Hive脚本中如何进行注释](#)
[2.7.11 显示字段名称](#)
[第3章 数据类型和文件格式](#)
[3.1 基本数据类型](#)
[3.2 集合数据类型](#)
[3.3 文本文件数据编码](#)
[3.4 读时模式](#)
[第4章 HiveQL: 数据定义](#)
[4.1 Hive中的数据库](#)
[4.2 修改数据库](#)
[4.3 创建表](#)
[4.3.1 管理表](#)
[4.3.2 外部表](#)
[4.4 分区表、管理表](#)
[4.4.1 外部分区表](#)
[4.4.2 自定义表的存储格式](#)
[4.5 删除表](#)
[4.6 修改表](#)
[4.6.1 表重命名](#)
[4.6.2 增加、修改和删除表分区](#)
[4.6.3 修改列信息](#)
[4.6.4 增加列](#)
[4.6.5 删除或者替换列](#)
[4.6.6 修改表属性](#)
[4.6.7 修改存储属性](#)
[4.6.8 众多的修改表语句](#)
[第5章 HiveQL: 数据操作](#)

[5.1 向管理表中装载数据](#)
[5.2 通过查询语句向表中插入数据](#)
[动态分区插入](#)
[5.3 单个查询语句中创建表并加载数据](#)
[5.4 导出数据](#)
第6章 HiveQL: 查询
[6.1 SELECT... FROM语句](#)
[6.1.1 使用正则表达式来指定列](#)
[6.1.2 使用列值进行计算](#)
[6.1.3 算术运算符](#)
[6.1.4 使用函数](#)
[6.1.5 LIMIT语句](#)
[6.1.6 列别名](#)
[6.1.7 嵌套SELECT语句](#)
[6.1.8 CASE ... WHEN ... THEN 句式](#)
[6.1.9 什么情况下Hive可以避免进行MapReduce](#)
[6.2 WHERE语句](#)
[6.2.1 谓词操作符](#)
[6.2.2 关于浮点数比较](#)
[6.2.3 LIKE和RLIKE](#)
[6.3 GROUP BY 语句](#)
[HAVING语句](#)
[6.4 JOIN语句](#)
[6.4.1 INNER JOIN](#)
[6.4.2 JOIN优化](#)
[6.4.3 LEFT OUTER JOIN](#)
[6.4.4 OUTER JOIN](#)
[6.4.5 RIGHT OUTER JOIN](#)
[6.4.6 FULL OUTER JOIN](#)
[6.4.7 LEFT SEMI-JOIN](#)
[6.4.8 笛卡尔积JOIN](#)
[6.4.9 map-side JOIN](#)
[6.5 ORDER BY和SORT BY](#)
[6.6 含有SORT BY 的DISTRIBUTE BY](#)
[6.7 CLUSTER BY](#)
[6.8 类型转换](#)
[类型转换BINARY值](#)

6.9 抽样查询

6.9.1 数据块抽样

6.9.2 分桶表的输入裁剪

6.10 UNION ALL

第7章 HiveQL: 视图

7.1 使用视图来降低查询复杂度

7.2 使用视图来限制基于条件过滤的数据

7.3 动态分区中的视图和map类型

7.4 视图零零碎碎相关的事情

第8章 HiveQL: 索引

8.1 创建索引

Bitmap索引

8.2 重建索引

8.3 显示索引

8.4 删除索引

8.5 实现一个定制化的索引处理器

第9章 模式设计

9.1 按天划分的表

9.2 关于分区

9.3 唯一键和标准化

9.4 同一份数据多种处理

9.5 对于每个表的分区

9.6 分桶表数据存储

9.7 为表增加列

9.8 使用列存储表

9.8.1 重复数据

9.8.2 多列

9.9 (几乎) 总是使用压缩

第10章 调优

10.1 使用EXPLAIN

10.2 EXPLAIN EXTENDED

10.3 限制调整

10.4 JOIN优化

10.5 本地模式

10.6 并行执行

10.7 严格模式

10.8 调整mapper和reducer个数

[10.9 JVM重用](#)
[10.10 索引](#)
[10.11 动态分区调整](#)
[10.12 推测执行](#)
[10.13 单个MapReduce中多个GROUP BY](#)
[10.14 虚拟列](#)

[第11章 其他文件格式和压缩方法](#)

[11.1 确定安装编解码器](#)
[11.2 选择一种压缩编/解码器](#)
[11.3 开启中间压缩](#)
[11.4 最终输出结果压缩](#)
[11.5 sequence file存储格式](#)
[11.6 使用压缩实践](#)
[11.7 存档分区](#)
[11.8 压缩: 包扎](#)

[第12章 开发](#)

[12.1 修改Log4J属性](#)
[12.2 连接Java调试器到Hive](#)
[12.3 从源码编译Hive](#)
[12.3.1 执行Hive测试用例](#)
[12.3.2 执行hook](#)
[12.4 配置Hive和Eclipse](#)
[12.5 Maven工程中使用Hive](#)
[12.6 Hive中使用hive test进行单元测试](#)
[12.7 新增的插件开发工具箱 \(PDK\)](#)

[第13章 函数](#)

[13.1 发现和描述函数](#)
[13.2 调用函数](#)
[13.3 标准函数](#)
[13.4 聚合函数](#)
[13.5 表生成函数](#)
[13.6 一个通过日期计算其星座的UDF](#)
[13.7 UDF与GenericUDF](#)
[13.8 不变函数](#)
[13.9 用户自定义聚合函数](#)
[创建一个COLLECT UDAF来模拟GROUP CONCAT](#)
[13.10 用户自定义表生成函数](#)

- 13.10.1 可以产生多行数据的UDTF
- 13.10.2 可以产生具有多个字段的单行数据的UDTF
- 13.10.3 可以模拟复杂数据类型的UDTF
- 13.11 在 UDF中访问分布式缓存
- 13.12 以函数的方式使用注解
- 13.12.1 定数性 (deterministic) 标注
- 13.12.2 状态性 (stateful) 标注
- 13.12.3 唯一性
- 13.13 宏命令
- 第14章 Streaming
 - 14.1 恒等变换
 - 14.2 改变类型
 - 14.3 投影变换
 - 14.4 操作转换
 - 14.5 使用分布式内存
 - 14.6 由一行产生多行
 - 14.7 使用streaming进行聚合计算
 - 14.8 CLUSTER BY、DISTRIBUTE BY、SORT BY
 - 14.9 GenericMR Tools for Streaming to Java
 - 14.10 计算cogroup
- 第15章 自定义Hive文件和记录格式
 - 15.1 文件和记录格式
 - 15.2 阐明CREATE TABLE句式
 - 15.3 文件格式
 - 15.3.1 SequenceFile
 - 15.3.2 RCfile
 - 15.3.3 示例自定义输入格式: DualInputFormat
 - 15.4 记录格式: SerDe
 - 15.5 CSV和TSV SerDe
 - 15.6 ObjectInspector
 - 15.7 Thing Big Hive Reflection ObjectInspector
 - 15.8 XML UDF
 - 15.9 XPath相关的函数
 - 15.10 JSON SerDe
 - 15.11 Avro Hive SerDe
 - 15.11.1 使用表属性信息定义Avro Schema
 - 15.11.2 从指定URL中定义Schema

[15.11.3 进化的模式](#)

[15.12 二进制输出](#)

[第16章 Hive的Thrift服务](#)

[16.1 启动Thrift Server](#)

[16.2 配置Groovy使用HiveServer](#)

[16.3 连接到HiveServer](#)

[16.4 获取集群状态信息](#)

[16.5 结果集模式](#)

[16.6 获取结果](#)

[16.7 获取执行计划](#)

[16.8 元数据存储方法](#)

[表检查器例子](#)

[16.9 管理HiveServer](#)

[16.9.1 生产环境使用HiveServer](#)

[16.9.2 清理](#)

[16.10 Hive ThriftMetastore](#)

[16.10.1 ThriftMetastore 配置](#)

[16.10.2 客户端配置](#)

[第17章 存储处理程序和NoSQL](#)

[17.1 Storage Handler Background](#)

[17.2 HiveStorageHandler](#)

[17.3 HBase](#)

[17.4 Cassandra](#)

[17.4.1 静态列映射 \(Static Column Mapping\)](#)

[17.4.2 为动态列转置列映射](#)

[17.4.3 Cassandra SerDe Properties](#)

[17.5 DynamoDB](#)

[第18章 安全](#)

[18.1 和Hadoop安全功能相结合](#)

[18.2 使用Hive进行验证](#)

[18.3 Hive中的权限管理](#)

[18.3.1 用户、组和角色](#)

[18.3.2 Grant 和 Revoke权限](#)

[18.4 分区级别的权限](#)

[18.5 自动授权](#)

[第19章 锁](#)

[19.1 Hive结合Zookeeper支持锁功能](#)

[19.2 显式锁和独占锁](#)

[第20章 Hive和Oozie整合](#)

[20.1 Oozie提供的多种动作 \(Action\)](#)

[Hive Thrift Service Action](#)

[20.2 一个只包含两个查询过程的工作流示例](#)

[20.3 Oozie 网页控制台](#)

[20.4 工作流中的变量](#)

[20.5 获取输出](#)

[20.6 获取输出到变量](#)

[第21章 Hive和亚马逊网络服务系统 \(AWS\)](#)

[21.1 为什么要弹性MapReduce](#)

[21.2 实例](#)

[21.3 开始前的注意事项](#)

[21.4 管理自有EMR Hive集群](#)

[21.5 EMR Hive上的Thrift Server服务](#)

[21.6 EMR上的实例组](#)

[21.7 配置EMR集群](#)

[21.7.1 部署hive-site.xml文件](#)

[21.7.2 部署.hiverc脚本](#)

[21.7.3 建立一个内存密集型配置](#)

[21.8 EMR上的持久层和元数据存储](#)

[21.9 EMR集群上的HDFS和S3](#)

[21.10 在S3上部署资源、配置和辅助程序脚本](#)

[21.11 S3上的日志](#)

[21.12 现买现卖](#)

[21.13 安全组](#)

[21.14 EMR和EC2以及Apache Hive的比较](#)

[21.15 包装](#)

[第22章 HCatalog](#)

[22.1 介绍](#)

[22.2 MapReduce](#)

[22.2.1 读数据](#)

[22.2.2 写数据](#)

[22.3 命令行](#)

[22.4 安全模型](#)

[22.5 架构](#)

[第23章 案例研究](#)

[23.1 m6d.com\(Media6Degrees\)](#)

[23.1.1 M 6D的数据科学. 使用Hive和R](#)

[23.1.2 M6D UDF伪随机](#)

[23.1.3 M6D如何管理多MapReduce集群间的Hive数据访问](#)

[23.2 Outbrain](#)

[23.2.1 站内线上身份识别](#)

[23.2.2 计算复杂度](#)

[23.2.3 会话化](#)

[23.3 NASA喷气推进实验室](#)

[23.3.1 区域气候模型评价系统](#)

[23.3.2 我们的经验: 为什么使用Hive](#)

[23.3.3 解决这些问题我们所面临的挑战](#)

[23.4 Photobucket](#)

[23.4.1 Photobucket 公司的大数据应用情况](#)

[23.4.2 Hive所使用的硬件资源信息](#)

[23.4.3 Hive提供了什么](#)

[23.4.4 Hive支持的用户有哪些](#)

[23.5 SimpleReach](#)

[23.6 Experiences and Needs from the Customer Trenches](#)

[标题: 来自Karmasphere的视角](#)

[23.6.1 介绍](#)

[23.6.2 Customer Trenches的用例](#)

[术语词汇表](#)

[书末说明](#)

[欢迎来到异步社区!](#)

版权信息

书名：Hive编程指南

ISBN：978-7-115-33383-4

本书由人民邮电出版社发行数字版。版权所有，侵权必究。

您购买的人民邮电出版社电子书仅供您个人使用，未经授权，不得以任何方式复制和传播本书内容。

我们愿意相信读者具有这样的良知和觉悟，与我们共同保护知识产权。

如果购买者有侵权行为，我们可能对该用户实施包括但不限于关闭该帐号等维权措施，并可能追究法律责任。

• 著 [美] Edward Capriolo Dean Wampler Jason Rutherford

译 曹 坤

责任编辑 汪 振

• 人民邮电出版社出版发行 北京市丰台区成寿寺路11号

邮编 100164 电子邮件 315@ptpress.com.cn

网址 <http://www.ptpress.com.cn>

• 读者服务热线：(010)81055410

反盗版热线：(010)81055315

版权声明

Copyright © 2013 by O'Reilly Media, Inc.

Simplified Chinese Edition, jointly published by O'Reilly Media, Inc. and Posts & Telecom Press, 2013. Authorized translation of the English edition, 2013 O'Reilly Media, Inc., the owner of all rights to publish and sell same.

All rights reserved including the rights of reproduction in whole or in part in any form.

本书中文简体字版由O'Reilly Media, Inc.授权人民邮电出版社出版。未经出版者书面许可，对本书的任何部分不得以任何方式复制或抄袭。

版权所有，侵权必究。

内容提要

本书是一本Apache Hive的编程指南，旨在介绍如何使用Hive的SQL方法——HiveQL来汇总、查询和分析存储在Hadoop分布式文件系统上的大数据集合。全书通过大量的实例，首先介绍如何在用户环境下安装和配置Hive，并对Hadoop和MapReduce进行详尽阐述，最终演示Hive如何在Hadoop生态系统进行工作。

本书适合对大数据感兴趣的爱好者以及正在使用Hadoop系统的数据库管理员阅读使用。

O'Reilly Media, Inc.介绍

O'Reilly Media通过图书、杂志、在线服务、调查研究和会议等方式传播创新知识。自1978年开始，O'Reilly一直都是前沿发展的见证者和推动者。超级极客们正在开创着未来，而我们关注真正重要的技术趋势——通过放大那些“细微的信号”来刺激社会对新科技的应用。作为技术社区中活跃的参与者，O'Reilly的发展充满了对创新的倡导、创造和发扬光大。

O'Reilly为软件开发人员带来革命性的“动物书”；创建第一个商业网站（GNN）；组织了影响深远的开放源代码峰会，以至于开源软件运动以此命名；创立了《Make》杂志，从而成为DIY革命的主要先锋；公司一如既往地通过多种形式缔结信息与人的纽带。O'Reilly的会议和峰会集聚了众多超级极客和高瞻远瞩的商业领袖，共同描绘出开创新产业的革命性思想。作为技术人士获取信息的选择，O'Reilly现在还将先锋专家的知识传递给普通的计算机用户。无论是通过书籍出版、在线服务或者面授课程，每一项O'Reilly的产品都反映了公司不可动摇的理念——信息是激发创新的力量。

业界评论

“O'Reilly Radar博客有口皆碑。”

——Wired

“O'Reilly凭借一系列（真希望当初我也想到了）非凡想法建立了数百万美元的业务。”

——Business 2.0

“O'Reilly Conference是聚集关键思想领袖的绝对典范。”

——CRN

“一本O'Reilly的书就代表一个有用、有前途、需要学习的主题。”

——Irish Times

“Tim是位特立独行的商人，他不光放眼于最长远、最广阔的视野并且切实地按照Yogi Berra的建议去做了：‘如果你在路上遇到岔路口，走小路（岔路）。’回顾过去Tim似乎每一次都选择了小路，而且有几次都是一闪即逝的机会，尽管大路也不错。”

——Linux Journal

作者简介

Edward Capriolo目前是Media6degrees公司的系统管理员，在这里他为互联网广告企业提供设计和维护分布式数据存储系统的服务。

Edward是Apache软件基金会的成员，同时也是Hadoop/Hive项目的贡献者。Edward具有软件开发经验，同时也具有Linux和网络管理员的经历，而且对于开源软件世界充满了热情。

Dean Wampler是ThinkBigAnalytics公司的首席顾问，其擅长“大数据”文件，以及像Hadoop这样的工具研究，还有机器学习相关的内容。除了擅长大数据，他还擅长Scala、JVM生态系统、JavaScript、Ruby、函数式以及面向对象编程，同时还擅长敏捷方法。Dean经常性地在工业和学术会议上就这些主题进行演讲。他还具有来自华盛顿大学的物理学博士学位。

Jason Rutherglen是Think Big Analytics公司的一名软件架构师，其擅长大数据、Hadoop、搜索和安全领域。

作者序

Edward Capriolo

当我第一次参与到Hadoop里时，我看到了分布式文件系统和MapReduce计算框架可以以一种伟大的方式来解决计算密集型的问题。然而，使用MapReduce编程模型进行编程曾经对于我来说是件非常麻烦的事情。Hive提供了一个类SQL的方式可以让我快速而又简单地利用到MapReduce计算的优势。这种方法也使得概念验证应用程序原型设计变得容易，同时在内部可以很好地使用Hadoop作为解决方案。尽管我现在非常熟悉Hadoop内核，Hive仍然是我利用Hadoop进行工作的主要方法。

能够参与编写一本关于Hive的书，对我来说是一件非常荣耀的事情；同时能够作为一名Hive代码贡献者和Apache软件基金会的成员也是我最有价值的荣誉。

Dean Wampler

作为Think Big Analytics公司的一名“大数据”顾问，我经常和一群具有丰富经验的SQL“数据人”一起工作。对他们来说，使用Hive是必要且充分的，这样才能使用Hadoop作为可行的工具，并利用他们的SQL知识来使用数据分析，开创新的机遇。

Hive缺乏良好的文档。我向O'Reilly出版社的编辑Mike Loukides建议，社区确实需要一本Hive相关的书籍。于是，本书应运而生……

Jason Rutherford

我是Think Big Analytics公司的一名软件架构师。我的职业生涯涉及一系列的技术，包括搜索、Hadoop、移动、密码学和自然语言处理。Hive是使用开源技术，基于海量数据构建数据仓库的最终方式。我在很多不同的项目中使用了Hive。

致谢

感谢参与到Hive中的每一个人。包括代码贡献者、参与者以及最终用户。

Mark Grove编写了Hive和亚马逊网络服务那一章的内容。他是一个Apache Hive项目的贡献者并在Hive IRC上非常积极地帮助他人。M6D公司的David Ha和Rumit Patel贡献了案例研究章节的内容和等级函数的代码。在Hive中可以进行排名是一个重要的特性。

M6D公司的Stitelman，贡献了案例研究章节中关于数据科学如何使用Hive和R的内容，其中演示了如何通过Hive对大数据集进行一次处理并提供了产生的结果，然后在之后的处理过程中使用R处理Hive产生的结果数据。

David Funk贡献了3个用例，即：站内引用链接识别、会话化、计数独立用户访问量。David的技术说明展示了如何重写和优化Hive查询可以使数据分析效率得到大幅度提高。Ian Robertson审阅了整个书的初稿并提供非常有用的反馈信息。我们非常感谢他，在时间很紧的短时间内提供了这些反馈。

John Sichi对本书进行了专业技术评审。John同时也帮助开发了Hive中的一些新特性，例如StorageHandlers和索引支持。他一直积极帮助支持Hive社区的成长。

Alan Gates，《Pig编程指南》的作者，贡献了关于HCatalog的那一章内容。Nanda Vijaydev贡献了关于Karmasphere公司如何将Hive进行增强并提供产品化那一章内容。Eric Lubow提供了关于SimpleReach公司的案例研究。Chris A. Mattmann、Paul Zimdars、Cameron Goodale、Andrew F. Hart、Jinwon Kim、Duane Waliser和Peter Lean共同贡献了美国宇航局喷气推进实验室（NASA JPL）的案例研究。

前言

本书是一本Hive的编程指南。Hive是Hadoop生态系统中必不可少的一个工具，它提供了一种SQL（结构化查询语言）方言，可以查询存储在Hadoop分布式文件系统（HDFS）中的数据或其他和Hadoop集成的文件系统，如MapR-FS、Amazon的S3和像HBase（Hadoop数据库）和Cassandra这样的数据库中的数据。

大多数数据仓库应用程序都是使用关系数据库进行实现的，并使用SQL作为查询语言。Hive降低了将这些应用程序转移到Hadoop系统上的难度。凡是会使用SQL语言的开发人员都可以很轻松地学习并使用Hive。如果没有Hive，那么这些用户就必须学习新的语言和工具，然后才能应用到生产环境中。另外，相比其他工具，Hive更便于开发人员将基于SQL的应用程序转移到Hadoop中。如果没有Hive，那么开发者将面临一个艰巨的挑战，如何将他们的SQL应用程序移植到Hadoop上。

不过，Hive和其他基于SQL的环境还是有一些差异的。如今，可供Hive用户和Hadoop开发者使用的文档并不多，所以我们决定撰写这本书来填补这个缺口。我们将对Hive进行全面详实的介绍，主要适用于SQL专家，如数据库设计人员和业务分析师。我们也谈到了深入的技术细节，可以帮助Hadoop开发人员对Hive进行调优和定制。

用户可以在本书的目录页面了解到更多信息：
http://oreil.ly/Programming_Hive。

本书中所使用的约定

本书中使用到了如下几种印刷字体。

斜体字

表明是新的术语、URL、电子邮件地址、文件名或者文件扩展名。

等宽字体

用于程序列表，同时段落中使用到了程序片段，例如变量或者函数名称、数据库、数据类型、环境变量、语句和关键字。

等宽粗体

表示是命令或者其他需要用户进行输入的文本。

等宽斜体

表示这个文本需要用户提供对应的值或者需要通过上下文才能获取到的值。



提示

这个图标表明是一个小技巧、建议或者一般性的注释。



警告

这个图标表明是个警告或者警示。

使用的代码示例

本书的目的是帮助用户完成他们的任务。通常情况下，用户可以在他们的程序和文档中使用本书中的代码。如此不需要联系我们以获取许可，除非明显地复制了代码的大部分内容。例如，写程序用到了本书中几个代码片段是不需要获得许可的，但是如果销售或者传播包含了O'Reilly系列书籍中的例子的CD光盘，那么就一定要获得我们的许可才行。在回答问题时引用到本书或以本书中的例子为引证时不需要获得许可，将一定数量的样例代码复制到自己的产品文档中则一定需要获得我们的许可才可以。

虽然并非是必需的，但如果可以注明出处，我们将十分感激。出处一般包括标题，作者，出版商和ISBN。例如：“Programming Hive by Edward Capriolo, Dean Wampler, and Jason Rutherglen (O'Reilly). Copyright 2012 Edward Capriolo, Aspect Research Associates, and Jason Rutherglen, 978-1-449-31933-5.”

如果用户感觉自己没有合理地或者在如上所述的许可范围内使用本书中代码样例的话，请尽管通过 permissions@oreilly.com联系我们。

Safari®在线图书



Safari在线图书是一个按需服务的数字图书馆。使用它，用户可以轻松检索超过7 500本技术和创意参考书以及视频教程，快速获得想知道的答案。

通过订阅，用户可以从我们的在线图书馆中阅读每一篇文章或观看每一部视频。通过用户的手机和其他移动设备看书。在书还没有印刷前就可以事先看到书目，还可以看到正在进行中的草稿，并可以将意见反馈给作者。复制粘贴代码样例，组织用户的收藏夹，下载一些章节，对关键章节标记标签，创建笔记，打印书籍内容，并通过其他众多的省时功能而受益。

O'Reilly公司已经将本书上传到 Safari图书在线服务。想获得对这本书的完整数据版访问权限以及其他来源于O'Reilly和其他出版商的对相同话题的讨论，请通过网址<http://my.safaribooksonline.com>免费注册账户。

如何联系到我们

请将对于本书的评论和问题通过如下地址发送给出版商：

O'Reilly Media, Inc.

1005 Gravenstein Highway North

Sebastopol, CA 95472

800-998-9938 (in the United States or Canada)

707-829-0515 (international or local)

707-829-0104 (fax)

在本书的官方页面中，我们列举了勘误表、例子和其他附加信息，用户可以通过以下链接访问：

http://oreil.ly/Programming_Hive

可以通过如下E-mail，将用户对本书的评论或技术方面的问题发给我们：

bookquestions@oreilly.com

想获得更多关于我们的系列书籍、会议、资源中心和O'Reilly网络公司，请通过如下网站查看：

<http://www.oreilly.com>

我们的Facebook地址是：<http://facebook.com/oreilly>

我们的Twitter地址是：<http://twitter.com/oreillymedia>

我们的YouTube地址是：<http://www.youtube.com/oreillymedia>

第1章 基础知识

从早期的互联网主流大爆发开始，主要的搜索引擎公司和电子商务公司就一直在和不断增长的数据进行较量。最近，社交网站也遇到了同样的问题。如今，许多组织已经意识到他们所收集的数据是让他们了解他们的用户，提高业务在市场上的表现以及提高基础架构效率的一个宝贵的资源。

*Hadoop*生态系统就是为处理如此大数据集而产生的一个合乎成本效益的解决方案。*Hadoop*实现了一个特别的计算模型，也就是 *MapReduce*，其可以将计算任务分割成多个处理单元然后分散到一群家用的或服务器级别的硬件机器上，从而降低成本并提供水平可伸缩性。这个计算模型的下面是一个被称为*Hadoop*分布式文件系统 (HDFS) 的分布式文件系统。这个文件系统是“可插拔的”，而且现在已经出现了几个商用的和开源的替代方案。

不过，仍然存在一个挑战，那就是用户如何从一个现有的数据基础架构转移到*Hadoop*上，而这个基础架构是基于传统关系型数据库和结构化查询语句 (SQL) 的。对于大量的SQL用户（包括专业数据库设计师和管理员，也包括那些使用SQL从数据仓库中抽取信息的临时用户）来说，这个问题又将如何解决呢？

这就是*Hive*出现的原因。*Hive*提供了一个被称为*Hive*查询语言（简称*HiveQL*或*HQL*）的SQL方言，来查询存储在*Hadoop*集群中的数据。

SQL知识分布广泛的一个原因是：它是一个可以有效地、合理地且直观地组织和使用数据的模型。即使对于经验丰富的Java开发工程师来说，将这些常见的数据运算对应到底层的*MapReduce* Java API也是令人畏缩的。*Hive*可以帮助用户来做这些苦活，这样用户就可以集中精力关注于查询本身了。*Hive*可以将大多数的查询转换为*MapReduce*任务 (job)，进而在介绍一个令人熟悉的SQL抽象的同时，拓宽*Hadoop*的可扩展性。如果用户对此存在疑惑，请参考稍后部分的第1.3节“Java和*Hive*：词频统计算法”中的相关介绍。

*Hive*最适合于数据仓库应用程序，使用该应用程序进行相关的静态数据分析，不需要快速响应给出结果，而且数据本身不会频繁变

化。

Hive不是一个完整的数据库。Hadoop以及HDFS的设计本身约束和局限性地限制了Hive所能胜任的工作。其中最大的限制就是Hive不支持记录级别的更新、插入或者删除操作。但是用户可以通过查询生成新表或者将查询结果导入到文件中。同时，因为Hadoop是一个面向批处理的系统，而MapReduce任务（job）的启动过程需要消耗较长的时间，所以Hive查询延时比较严重。传统数据库中在秒级别可以完成的查询，在Hive中，即使数据集相对较小，往往也需要执行更长的时间[\[1\]](#)。最后需要说明的是，Hive不支持事务。

因此，Hive不支持OLTP（联机事务处理）所需的关键功能，而更接近成为一个OLAP（联机分析技术）工具。但是我们将会看到，由于Hadoop本身的时间开销很大，并且Hadoop所被设计用来处理的数据规模非常大，因此提交查询和返回结果是可能具有非常大的延时的，所以Hive并没有满足OLAP中的“联机”部分，至少目前并没有满足。

如果用户需要对大规模数据使用OLTP功能的话，那么应该选择使用一个NoSQL数据库，例如，和Hadoop结合使用的HBase[\[2\]](#)及Cassandra[\[3\]](#)。如果用户使用的是Amazon弹性MapReduce计算系统（EMR）或者弹性计算云服务（EC2）的话，也可以使用DynamoDB[\[4\]](#)。用户甚至可以和这些数据库（还包括其他一些数据库）结合来使用Hive，这个我们会在第17章进行介绍。

因此，Hive是最适合数据仓库应用程序的，其可以维护海量数据，而且可以对数据进行挖掘，然后形成意见和报告等。

因为大多数的数据仓库应用程序是使用基于SQL的关系型数据库实现的，所以Hive降低了将这些应用程序移植到Hadoop上的障碍。用户如果懂得SQL，那么学习使用Hive将会很容易。如果没有Hive，那么这些用户就需要去重新学习新的语言和新的工具后才能进行生产。

同样地，相对于其他Hadoop语言和工具来说，Hive也使得开发者将基于SQL的应用程序移植到Hadoop变得更加容易。

不过，和大多数SQL方言一样，HiveQL并不符合ANSI SQL标准，其和Oracle，MySQL，SQL Server支持的常规SQL方言在很多方面存在差异（不过，HiveQL和MySQL提供的SQL方言最接近）。

因此，本书共有两个目的。其一，本书提供了一个针对所有用户的介绍。这个介绍会比较综合，并且会使用例子来进行讲解。适用的用户包括开发者、数据库管理员和架构师，以及其他（如商业分析师等）非技术类用户。

其二，本书针对开发者和Hadoop管理员等需要深入了解Hive技术细节的用户提供了更详尽的讲述，以帮助这些用户学习如何优化Hive查询性能，如何通过用户自定义函数和自定义数据格式等，来个性化使用Hive。

因为Hive缺少好的文档，所以我们经历了不少的挫折才完成了这本书。特别是对于那些非开发者以及不习惯通过查看项目BUG记录和功能数据库、源代码等途径来获取其所需信息的用户，Hive并没有提供好的文档。Hive Wiki^[5]提供的信息价值很大，但是其中的解释有时太少了，而且常常没有进行及时的更新。我们希望本书可以弥补这些不足，可以提供一个对于Hive的所有基本功能以及如何高效使用这些功能的综合性的指南^[6]。

1.1 Hadoop和MapReduce综述

如果用户已经熟悉Hadoop和MapReduce计算模型的话，那么可以跳过本节。虽然用户无需精通MapReduce就可以使用Hive，但是理解MapReduce的基本原理将有助于用户了解Hive在底层是如何运作的，以及了解如何才能更高效地使用Hive。

我们在这里提供了一个关于Hadoop和MapReduce的简要描述。更多细节，请参考Tom White (O'Reilly)所著的《Hadoop权威指南》一书。

MapReduce

MapReduce是一种计算模型，该模型可将大型数据处理任务分解成很多单个的、可以在服务器集群中并行执行的任务。这些任务的计算结果可以合并在一起计算最终的结果。

MapReduce编程模型是由谷歌(Google)开发的。Google通过一篇很有影响力的论文对这个计算模型进行了描述，本书附录部分可查看到

该论文，名为《MapReduce：大数据之上的简化数据处理》。一年后，另一篇名为《Google文件系统》的论文介绍了Google文件系统。这两篇论文启发了道·卡丁（Doug Cutting）开发了Hadoop。

MapReduce这个术语来自于两个基本的数据转换操作：map过程和reduce过程。一个map操作会将集合中的元素从一种形式转换成另一种形式。在这种情况下，输入的键-值对会被转换成零到多个键-值对输出。其中，输入和输出的键必须完全不同，而输入和输出的值则可能完全不同。

在MapReduce计算框架中，某个键的所有键-值对都会被分发到同一个reduce操作中。确切地说，这个键和这个键所对应的所有值都会被传递给同一个Reducer。reduce过程的目的是将值的集合转换成一个值（例如对一组数值求和或求平均值），或者转换成另一个集合。这个Reducer最终会产生一个键-值对。再次说明一下，输入和输出的键和值可能是不同的。需要说明的是，如果job不需要reduce过程的话，那么也是可以无reduce过程的。

Hadoop提供了一套基础设施来处理大多数困难的工作以保证任务能够执行成功。例如，Hadoop决定如果将提交的job分解成多个独立的map和reduce任务（task）来执行，它就会对这些task进行调度并为其分配合适的资源，决定将某个task分配到集群中哪个位置（如果可能，通常是这个task所要处理的数据所在的位置，这样可以最小化网络开销）。它会监控每一个task以确保其成功完成，并重启一些失败的task。

Hadoop分布式文件系统（也就是HDFS），或者一个同类的分布式文件系统，管理着集群中的数据。每个数据块（block）都会被冗余多份（通常默认会冗余3份），这样可以保证不会因单个硬盘或服务器的损坏导致数据丢失。同时，因为其目标是优化处理非常大的数据集，所以HDFS以及类似的文件系统所使用的数据块都非常大，通常是64MB或是这个值的若干倍。这么大的数据块可以在硬盘上连续进行存储，这样可以保证以最少的磁盘寻址次数来进行写入和读取，从而最大化提高读写性能。

为了更清晰地介绍MapReduce，让我们来看一个简单的例子。Word Count算法已经被称为是MapReduce计算框架中的“Hello World”程序^[7]了。Word Count会返回在语料库（单个或多个文件）中出现的所有

单词以及单词出现的次数。输出内容会显示每个单词和它的频数，每行显示一条。按照通常的习惯，单词（输出的键）和频数（输出的值）通常使用制表符进行分割。

图1-1 显示了在MapReduce计算框架中Word Count程序是如何运作的。




图1-1 使用MapReduce执行WordCount算法

这里有很多内容要讲，所以我们会从左到右来讲解这个图。

图1-1中左边的每个Input（输入）框内都表示一个单独的文件。例子中有4个文件，其中第3个文件是个空文件，为了便于简单描述，其他3个文件都仅仅包含有少量几个单词。

默认情况下，每个文档都会触发一个Mapper进程进行处理。而在实际场景下，大文件可能会被划分成多个部分，而每个部分都会被发送给一个Mapper进行处理。同时，也有将多个小文件合并成一个部分供某个Mapper进行处理的方法。不过，我们当前不必深究这些细节性问题。

MapReduce计算框架中的输入和输出的基本数据结构是键-值对。当Mapper进程启动后，其将会被频繁调用来处理文件中的每行文本。每次调用中，传递给Mapper的键是文档中这行的起始位置的字符偏移量。对应的值是这行对应的文本。

在WordCount程序中，没有使用字符偏移量（也就是没有使用键）。值（也就是这行文本）可以使用很多种方式进行分割（例如，按照空格分隔是最简单的方式，但是这样会遗留下不需要的标点符号），最终这行文本会被分解成多个单词。我们同时假定Mapper会将每个单词转换成小写，因此对于“FUN”和“fun”会被认为是同一个单词。

最后，对于这行文本中的每个单词，Mapper都会输出一个键-值对，以单词作为键并以数字1作为值（这里1表示“出现1次”）。需要注意的是键和值的输出数据类型和输入数据类型是不同的。

Hadoop神奇的地方一部分在于后面要进行的Sort（排序）和Shuffle（重新分发）过程。Hadoop会按照键来对键-值对进行排序，然后“重新洗牌”，将所有具有相同键的键-值对分发到同一个Reducer中。这里有多种方式可以用于决定哪个Reducer获取哪个范围内的键对应的数据。这里我们先不必考虑这些问题。但是出于说明性目的，我们假设图中使用了一个特殊的按字母数字划分的过程（在实际执行中，会有所不同）。

对于Mapper而言如果只是简单地对每个单词输出计数1这样的处理的话，那么会在Sort和Shuffle过程中产生一定的网络和磁盘I/O浪费（不过，这样并不会减少Mapper的内存使用）。有一个优化就是跟踪每个单词的频数，然后在Mapper结束后只输出每个单词在这个Mapper中的总频数。对于这个优化有好几种实现方式，但是，最简单的方式应该是逻辑是正确的，而且对于这个讨论，理由是充足的。

每个Reducer的输入同样是键-值对，但是这次，每个键将是Mapper所发现的单词中的某一个单词，而这个键对应的值将是所有Mapper对于这个单词计算出的频数的一个集合。需要注意的是键的数据类型和值的集合中元素的数据类型和Mapper的输出是一致的。也就是说，键的类型是一个字符串，而集合中的元素的数据类型是整型。

为了完成这个算法，所有的Reducer需要做的事情就是将值集合中的频数进行求和然后写入每个单词和这个单词最终的频数组成的键-值对。

Word Count不是一个虚构的例子。这个程序所产生的数据可用于拼写检查程序、计算机语言检测和翻译系统，以及其他应用程序。

1.2 Hadoop生态系统中的Hive

WordCount算法，和基于Hadoop实现的大多数算法一样，有那么点复杂。当用户真正使用Hadoop的API来实现这种算法时，甚至有更多的底层细节需要用户自己来控制。这是一个只适用于有经验的Java开发人员的工作，因此也就将Hadoop潜在地放在了一个非程序员用户无法触及的位置，即使这些用户了解他们想使用的算法。

事实上，许多这些底层细节实际上进行的是从一个任务（job）到下一个任务（job）的重复性工作，例如，将Mapper和Reducer一同写入某些数据操作构造这样的底层的繁重的工作，通过过滤得到所需数据的操作，以及执行类似SQL中数据集键的连接（JOIN）操作等。不过幸运的是，存在一种方式，可以通过使用“高级”工具自动处理这些情况来重用这些通用的处理过程。

这也就是引入Hive的原因。Hive不仅提供了一个熟悉SQL的用户所能熟悉的编程模型，还消除了大量的通用代码，甚至是那些有时是不得不使用Java编写的令人棘手的代码。

这就是为什么Hive对于Hadoop是如此重要的原因，无论用户是DBA还是Java开发工程师。Hive可以让你花费相当少的精力就可以完成大量的工作。

图1-2显示了Hive的主要“模块”以及Hive是如何与Hadoop交互工作的。




图1-2 Hive组成模块

有好几种方式可以与Hive进行交互。本书中，我们将主要关注于CLI，也就是命令行界面。对于那些更喜欢图形用户界面的用户，可以使用现在逐步出现的商业和开源的解决方案，例如Karmasphere发布的一个商业产品（<http://karmasphere.com>），Cloudera提供的开源的Hue项

目 (<https://github.com/cloudera/hue>)，以及Qubole提供的“Hive即服务”方式 (<http://qubole.com>)，等。

Hive发行版中附带的模块有CLI，一个称为Hive网页界面 (HWI) 的简单网页界面，以及可通过JDBC、ODBC和一个Thrift服务器（参考第16章）进行编程访问的几个模块。

所有的命令和查询都会进入到Driver（驱动模块），通过该模块对输入进行解析编译，对需求的计算进行优化，然后按照指定的步骤执行（通常是启动多个MapReduce任务（job）来执行）。当需要启动MapReduce任务（job）时，Hive本身是不会生成Java MapReduce算法程序的。相反，Hive通过一个表示“job执行计划”的XML文件驱动执行内置的、原生的Mapper和Reducer模块。换句话说，这些通用的模块函数类似于微型的语言翻译程序，而这个驱动计算的“语言”是以XML形式编码的。

Hive通过和JobTracker通信来初始化MapReduce任务（job），而不必部署在JobTracker所在的管理节点上执行。在大型集群中，通常会有网关机专门用于部署像Hive这样的工具。在这些网关机上可远程和管理节点上的JobTracker通信来执行任务（job）。通常，要处理的数据文件是存储在HDFS中的，而HDFS是由NameNode进行管理的。

Metastore（元数据存储）是一个独立的关系型数据库（通常是一个MySQL实例），Hive会在其中保存表模式和其他系统元数据。在我们将详细进行讨论。

尽管本书是关于Hive的，不过还是有必要提及其他的一些高级工具，这样用户可以根据需求进行选择。Hive最适合于数据仓库程序，对于数据仓库程序不需要实时响应查询，不需要记录级别的插入、更新和删除。当然，Hive也非常适合于有一定SQL知识的用户。不过，用户的某些工作可能采用其他的工具会更容易进行处理。

1.2.1 Pig

Hive的替代工具中最有名的就是Pig了（请参考 <http://pig.apache.org>）。Pig是由Yahoo!开发完成的，而同时期Facebook正在开发Hive。Pig现在同样也是一个和Hadoop紧密联系的顶级Apache项目。

假设用户的输入数据具有一个或者多个源，而用户需要进行一组复杂的转换来生成一个或者多个输出数据集。如果使用Hive，用户可能会使用嵌套查询（正如我们将看到的）来解决这个问题，但是在某些时刻会需要重新保存临时表（这个需要用户自己进行管理）来控制复杂度。

Pig被描述成一种数据流语言，而不是一种查询语言。在Pig中，用户需要写一系列的声明语句来定义某些关系和其他一些关系之间的联系，这里每个新的关系都会执行新的数据转换过程。Pig会查找这些声明，然后创建一系列有次序的MapReduce任务（job），来对这些数据进行转换，直到产生符合用户预期的计算方式所得到的最终结果。

这种步进式的数据“流”可以比一组复杂的查询更加直观。也因此，Pig常用于ETL（数据抽取，数据转换和数据装载）过程的一部分，也就是将外部数据装载到Hadoop集群中，然后转换成所期望的数据格式。

Pig的一个缺点就是其所使用的定制语言不是基于SQL的。这是可以理解的，因为Pig本身就不被设计为一种查询语言的，但是这也意味着不适合将SQL应用程序移植到Pig中，而经验丰富的SQL用户可能需要投入更高的学习成本来学习Pig。

然而，Hadoop团队通常会将Hive和Pig结合使用，对于特定的工作选择合适的工具。

Alan Gates（O'Reilly）所编著的《Pig编程指南》一书对于Pig进行了全面的介绍。

1.2.2 HBase

如果用户需要Hive无法提供的数据库特性（如行级别的更新，快速的查询响应时间，以及支持事务）的话，那么该怎么办呢？

HBase是一个分布式的、可伸缩的数据存储，其支持行级别的数据更新、快速查询和行级事务（但不支持多行事务）。

HBase的设计灵感来自于谷歌（Google）的BigTable，不过HBase并没有实现BigTable的所有特性。HBase支持的一个重要特性就是列存

储，其中的列可以组织成列族。列族在分布式集群中物理上是存储在一起的。这就使得当查询场景涉及的列只是所有列的一个子集时，读写速度会快得多。因为不需要读取所有的行然后丢弃大部分的列，而是只需读取需要的列。

可以像键-值存储一样来使用HBase，其每一行都使用了一个唯一键来提供非常快的速度读写这一行的列或者列族。HBase还会对每个列保留多个版本的值（按照时间戳进行标记），版本数量是可以配置的，因此，如果需要，可以“时光倒流”回退到之前的某个版本的值。

最后，HBase和Hadoop之间是什么关系？HBase使用HDFS（或其他某种分布式文件系统）来持久化存储数据。为了可以提供行级别的数据更新和快速查询，HBase也使用了内存缓存技术对数据和本地文件进行追加数据更新操作日志。持久化文件将定期地使用附加日志更新进行更新等操作。

HBase没有提供类似于SQL的查询语言，但是Hive现在已经可以和HBase结合使用了。在第17.3节“HBase”中我们将讨论这个结合。

关于HBase的更多信息，请参考HBase的官方网站，以及参阅Lars George所著的《HBase权威指南》一书。

1.2.3 Cascading、Crunch及其他

Apache Hadoop生态系统之外还有几个“高级”语言，它们也在Hadoop之上提供了不错的抽象来减少对于特定任务（job）的底层编码工作。为了叙述的完整性，下面我们列举其中的一些来进行介绍。所有这些都是JVM（Java虚拟机）库，可用于像Java、Clojure、Scala、JRuby、Groovy和Jython，而不是像Hive和Pig一样使用自己的语言工具。

使用这些编程语言既有好处也有弊端。它使这些工具很难吸引熟悉SQL的非程序员用户。不过，对于开发工程师来说，这些工具提供了图灵完全的编程语言的完全控制。Hive和Pig都是图灵完全性的（译者注：图灵完全性通常是指具有无限存储能力的通用物理机器或编程语言）。当我们需要Hive本身没有提供的额外功能时，我们需要学习如何用Java编码来扩展Hive功能（见表1-1）。

表1-1 其他可选的Hadoop之上的高级语言库

名称	URL	描述
Casading	http://cascading.org	提供数据处理抽象的Java API。目前有很多支持Casading的特定领域语言(DSL)，采用的是其他的编程语言，例如Scala、Groovy、JRuby和Jython
Casalog	https://github.com/nathanmarz/cascaLog	Casading的一个Clojure DSL，其提供了源于Datalog处理和查询抽象过程灵感而产生的附属功能
Crunch	https://github.com/cloudera/crunch	提供了可定义数据流管道的Java和Scala API

因为Hadoop是面向批处理系统的，所以存在更适合事件流处理的使用不同的分布式计算模式的工具。对事件流进行处理时，需要近乎“实时”响应。这里我们列举了其中一些项目（见表1-2）。

表1-2 没有使用MapReduce的分布式处理工具

名称	URL	描述
Spark	http://www.spark-project.org/	一个基于Scala API的分布式数据集的分布式计算框架。其可以使用HDFS文件，而且其对于MapReduce中多种计算可以提供显著的性能改进。同时还还有一个将Hive指向Spark的项目，称作Shark (http://shark.cs.berkeley.edu/)
Storm	https://github.com/nathanmarz/storm	一个实时事件流处理系统
Kafka	http://incubator.apache.org/kafka/index.html	一个分布式的发布-订阅消息传递系统

最后，当无需一个完整的集群时（例如，处理的数据集很小，或者对于执行某个计算的时间要求并不苛刻），还有很多可选的工具可以轻松地处理原型算法或者对数据子集进行探索。表1-3列举了一些相对比较热门的工具。

表1-3 其他数据处理语言和工具

名称	URL	描述
R	http://r-project.org/	一个用于统计分析和数据图形化展示的开源语言，通常在数据与统计学家、经济学家等人群中很受欢迎。R不是一个分布式系统，所有其可以处理的数据大小是有限的。社区正努力将R和Hadoop结合起来
Matlab	http://www.mathworks.com/products/matlab/index.html	一个受工程师和科学家欢迎的商业数据分析和数值方法计算系统
Octave	http://www.gnu.org/software/octave/	Matlab对应的一个开源版
Mathematica	http://www.wolfram.com/mathematica/	一个商业数据分析、人工智能和数值方法运算系统，这是个可以受科学家和工程师欢迎的工具
SciPy, NumPy	http://scipy.org	数据科学家广泛使用的、使用Python进行科学编程的软件

1.3 Java和Hive：词频统计算法

如果用户不是Java工程师，那么可以直接跳到下一节。

如果用户是名Java工程师，那么可能需要阅读本节，因为用户需要为其所在组织的Hive用户提供技术支持。你可能会质疑如何使用Hive解决自己的工作。如果是这样的话，那么可以先看看下面这个实现了

之前我们所讨论的Word Count算法的例子，我们先学会使用Java MapReduce API，然后再学习如何使用Hive。

通常都会使用Word Count作为用户学习使用Java编写MapReduce程序的例子，因为这样用户可以关注于API。因此，Word Count已经成为Hadoop世界中的“Hello World”程序了。

Apache Hadoop 分支版本中包含有下面的这个Java实现^[8]。如果读者并不了解Java（但是你仍在读本节内容的话），也不必担心，我们提供这个代码只是为了方便用户进行大小对比。

```
package org.myorg;

import java.io.IOException;
import java.util.*;

import org.apache.hadoop.fs.Path;
import org.apache.hadoop.conf.*;
import org.apache.hadoop.io.*;
import org.apache.hadoop.mapreduce.*;
import org.apache.hadoop.mapreduce.lib.input.FileInputFormat;
import org.apache.hadoop.mapreduce.lib.input.TextInputFormat;
import org.apache.hadoop.mapreduce.lib.output.FileOutputFormat;
import org.apache.hadoop.mapreduce.lib.output.TextOutputFormat;

public class WordCount {

    public static class Map extends Mapper<LongWritable, Text, Text, IntWritable> {
        private final static IntWritable one = new IntWritable(1);
        private Text word = new Text();

        public void map(LongWritable key, Text value, Context context)
            throws IOException, InterruptedException {
            String line = value.toString();
            StringTokenizer tokenizer = new StringTokenizer(line);
            while (tokenizer.hasMoreTokens()) {
                word.set(tokenizer.nextToken());
                context.write(word, one);
            }
        }
    }

    public static class Reduce extends Reducer<Text, IntWritable, Text, IntWritable> {
        public void reduce(Text key, Iterable<IntWritable> values, Context context)
            throws IOException, InterruptedException {
            int sum = 0;
            for (IntWritable val : values) {
                sum += val.get();
            }
            context.write(key, new IntWritable(sum));
        }
    }
}
```

```
public static void main(String[] args) throws Exception {
    Configuration conf = new Configuration();
    Job job = new Job(conf, "wordcount");
    job.setOutputKeyClass(Text.class);
    job.setOutputValueClass(IntWritable.class);
    job.setMapperClass(Map.class);
    job.setReducerClass(Reduce.class);
    job.setInputFormatClass(TextInputFormat.class);
    job.setOutputFormatClass(TextOutputFormat.class);
    FileInputFormat.addInputPath(job, new Path(args[0]));
    FileOutputFormat.setOutputPath(job, new Path(args[1]));
    job.waitForCompletion(true);
}
```

上面是一个有63行的Java代码。我们不会详细解释其中的API^[9]。如下是使用HiveQL进行的相同的运算，这时只有8行代码，而且不需要进行编译然后生成一个“JAR”（Java压缩包）文件。

```
CREATE TABLE docs (line STRING);
LOAD DATA INPATH 'docs' OVERWRITE INTO TABLE docs;
CREATE TABLE word*counts AS
SELECT word, count(1) AS count FROM
  (SELECT explode(split(line, '\s')) AS word FROM docs) w
GROUP BY word
ORDER BY word;
```

我们稍后会解释所有这些HiveQL语法。

在上面两个例子中，都是使用尽可能简单的方法将文件中的内容分割成单词，也就是按照空格进行划分的。这个方法不能很好地处理标点，同时也不能识别同一个单词的单数和复数形式，等等。不过，这里这么使用已经可以达到我们的目的了。^[10]

借助Java API可以定制和调整一个算法实现的每个细节。不过，大多数情况下，用户都不需要这个级别的控制，而且当用户需要控制所有那些细节时也会相当地放慢用户的开发进度。

如果你不是一名程序员，那么也就用不着写Java MapReduce代码了。不过，如果你已经熟悉SQL了，那么学习Hive将会相当地容易，而且很多程序也都很容易快速实现。

1.4 后续事情

我们描述了Hive在Hadoop生态系统中所扮演的重要角色。现在我们开始！

[1]不过，因为Hive是被设计用来处理的大数据集的，这个启动所消耗的时间和实际数据处理时间相比是微乎其微的。

[2]请访问Apache HBase的官方网站，<http://hbase.apache.org>，以及Lars George(O'Reilly)所著的《HBase权威指南》一书。

[3]请参考Cassandra的官方网站，<http://cassandra.apache.org/>，以及参考Edward Capriolo (Packt)所著的《High Performance Cassandra Cookbook》一书。

[4]请参考DynamoDB的官方网站，<http://aws.amazon.com/dynamodb/>。

[5]参考链接 <https://cwiki.apache.org/Hive/>。

[6]不过，非常有必要将这个wiki链接加入到网址收藏夹中，因为wiki中包含了一些我们没有覆盖的、比较模糊的信息。

[7]对于不是开发者的用户，这里需要补充说明的是“Hello World”程序通常是学习一门新的语言或者工具集的第一个程序。

[8]Apache Hadoop word count: <http://wiki.apache.org/hadoop/WordCount>.

[9]详细信息请参考Tom White所著的《Hadoop权威指南》一书。

[10]还有一个微小的差异。Hive查询硬编码指定一个指向数据的路径，而Java代码把这个路径作为一个输入参数处理。在第2章，我们将学习如何在Hive脚本中使用*变量*来避免这种硬编码。

第2章 基础操作

让我们来在个人工作站上安装Hadoop和Hive吧。这是学习和体验Hadoop的一个便捷的方式。之后我们将讨论如何配置Hive以了解如何在Hadoop集群上使用Hive。

如果用户已经在使用亚马逊网络服务（AWS）了，那么建立一个供学习Hive的最快速途径是在亚马逊弹性MapReduce系统（EMR）中提交一个Hive任务。我们在第21章将会讨论这种方式。

如果用户已经会使用安装有Hive的Hadoop集群的话，那么我们建议可以跳过本章的第一部分而直接从”开始看”。

2.1 安装预先配置好的虚拟机

用户可以通过多种方式来安装Hadoop和Hive。安装一个完整的Hadoop系统（包含有Hive）的一个最容易的方式就是下载一个预先配置好的虚拟机（VM），这个虚拟机可以在VMWare^[1]或者VirtualBox^[2]中执行。对于VMWare，可以使用Windows或Linux（免费的）的VMWarePlayer，也可以使用Mac OS X（需付费但并不贵）的VMWareFusion。VirtualBox在这些平台（包含有Solaris平台）中都是免费的。

虚拟机使用Linux作为操作系统，这也是在生产情况下运行Hadoop的唯一指定操作系统^[3]。



提示

在Windows系统中目前使用Hadoop的唯一方式就是使用虚拟机，即使安装了Cygwin或其他类似的类UNIX软件。

目前提供的大多数预先配置好的虚拟机（VM）仅是为VMWare设计的，但是如果用户偏好使用VirtualBox，那么也是可以在网站上找到如何将某个特定的VM导入到VirtualBox的指南的。

用户可以从表2-1^[4]提供的网站中下载指定的预先配置好的虚拟机。根据这些网站上的指南可以下载并导入到VMWare的虚拟机。

表2-1 为VMWare提供的预先配置好的Hadoop虚拟机

提供者	URL	注意事项
Cloudera.Inc	https://ccp.cloudera.com/display/SUPPORT/Cloudera's+Hadoop+Demo+VM	使用Cloudera自己的Hadoop分支，CDH3或者CDH4
MapR.Inc	http://www.mapr.com/doc/display/MapR/Quick+Start--+Test+Drive+MapR+on+a+Virtual+Machine	MapR的Hadoop分支，其将HDFS替换为了MapR文件系统(MapR-F5)
Hortonworks.Inc	http://docs.hortonworks.com/HDP-1.0.4-PREVIEW-6/Using_HDP_Single_Box_VM/HDP_Single_Box_VM.htm	基于最新的稳定的Apache的发行版
Think Big Analytics.Inc	http://thinkbigacademy.s3-website-us-east-1.amazonaws.com/vm/README.html	基于最新的稳定的Apache的发行版

下一步，可以直接从第2.3节“Hive内部是什么”开始看。

2.2 安装详细步骤

虽然使用一个预先配置好的虚拟机可能是使用Hive的一个便捷方式，但是自己安装Hadoop和Hive可以让用户更清楚地知道这些工具是如何工作的，特别是，如果用户是一个开发者的话，这个很重要。

下面所提供的指南描述的是在用户个人Linux或者Mac OS X工作站中安装Hadoop和Hive所必需的最少的步骤。对于生产环境下的安装过

程, 请查阅所使用的Hadoop分支推荐的安装流程。

2.2.1 装Java

Hive依赖于Hadoop, 而Hadoop依赖于Java。用户需要确认使用的操作系统中安装有v1.6.*或者v1.7.*版本的JVM (Java虚拟机)。尽管用户执行Hive只需要使用到JRE (Java运行时环境), 但是本书中还是演示了如何使用Java编码对Hive进行扩展, 因此用户还需要安装完整的JDK (Java开发工具集) 来编译这些例子。但是, 如果用户不是开发者, 可以不进行此操作, 本书所附带的源码分支版本中已经包含有编译过的例子了。

安装完成后, 用户需要确认Java已经存在于环境中, 而且已经设置好了JAVA_HOME环境变量。

1. Linux系统中Java安装步骤

在Linux操作系统上, 下面的指令是在`/etc/profile.d/`目录下创建一个`bash`文件, 其为所有的用户定义了一个JAVA_HOME环境变量, 需要root访问权限才能够修改这个目录下的环境变量设置, 而且修改将会影响到系统中所有用户。(我们使用\$作为`bash shell`提示符。) Oracle JVM安装程序通常会将软件安装在`/usr/java/jdk-1.6.X` (对于v1.6版本) 目录下, 而且会从`/usr/java/default`和`/usr/java/latest`路径建立软链接到安装路径下。

```
$ /usr/java/latest/bin/java -version
java version "1.6.0_23"
Java(TM) SE Runtime Environment (build 1.6.0_23-b05)
Java HotSpot(TM) 64-Bit Server VM (build 19.0-b09, mixed mode)
$ sudo echo "export JAVA_HOME=/usr/java/latest" > /etc/profile.d/java.sh
$ sudo echo "PATH=$PATH: $JAVA_HOME/bin" >> /etc/profile.d/java.sh
$ . /etc/profile
$ echo $JAVA_HOME
/usr/java/latest
```



提示

如果之前是使用“特权账号”来执行某个命令, 而不是在执行命令前使用`sudo`命令来执行的话 (也就是需要执行的命令分为两

部分： `sudo` 加上用户需要执行的命令），那么只需要按照提示要求输入密码即可。如果是个人计算机的话，用户账号通常就具有“`sudo`权限”。如果没有这个权限，可以联系管理员执行那些命令。

不过，如果用户不期望修改影响到系统里所有的用户，一个替代方案就是，将 `PATH` 和 `JAVA_HOME` 环境变量的定义加入到用户的 `$HOME/.bashrc` 文件中。

```
export JAVA_HOME=/usr/java/latest
export PATH=$PATH:$JAVA_HOME/bin
```

2. Mac OS X系统中Java安装步骤

Mac OS X系统没有 `/etc/profile.d` 这样的目录，而且它们通常是单用户系统，因此最好将环境变量的定义语句放置在 `$HOME/.bashrc` 文件中。Java路径同样也是不同的，而且可以位于多个不同的位置^[5]。这里有一些例子。用户需要确认自己的Mac电脑中Java的安装路径，然后对下面的定义进行相应的调整。下面是Mac OS X系统中Java 1.6的环境配置实例：

```
$ export JAVA_HOME=/System/Library/Frameworks/JavaVM.framework/Versions/ 1.6/Home
$ export PATH=$PATH:$JAVA_HOME/bin
```

下面是Mac OS X系统中Java 1.7的环境配置实例。

```
$ export JAVA_HOME=/Library/Java/JavaVirtualMachines/1.7.0.jdk/Contents/ Home
$ export PATH=$PATH:$JAVA_HOME/bin
```

OpenJDK 1.7发行版也是安装在 `/Library/Java/JavaVirtualMachines` 目录下的。

2.2.2 安装Hadoop

Hive运行在Hadoop之上。Hadoop是一个非常活跃的开源项目，其具有很多的发行版和分支。同时，很多的商业软件公司现在也在开发他们自己的Hadoop分支，有时会对某些组件进行个性化的增强或者替换。这种形式可以促进创新，但是同时也会产生潜在的混乱和兼容性问题。

保持使用最新版本的软件可以让用户使用最新的增强功能并且新版本通常会修复很多的BUG。随后，有时用户可能会发现新的BUG以及兼容性问题。本书中，我们将介绍如何安装Apache Hadoop v0.20.2发行版。这个版本并非是最新稳定发行版，但是这个版本是性能和兼容性都可以信赖的一个标准版。

不过，用户应该能够毫无问题地选择一个不同版本、分支或者发行版来学习和使用Hive，例如Apache Hadoop v0.20.205版本或者1.0.*版本，Cloudera的CDH3或者CDH4版本，MapR的M3或者M5版本，以及即将面市的Hortonworks 分支版本。注意Cloudera，MapR以及未来的Hortonworks分支版都包含有一个捆绑的Hive发行版。

不过，我们不建议安装新的阿尔法版的“下一代的”Hadoop v2.0版本（也就是所谓的v0.23版），至少本书的目标不是这个版本。虽然这个发行版将给Hadoop生态圈带来重大的增强，但是对于我们来说太新了。

在Linux系统中，可以通过执行如下命令安装Hadoop。注意：对于wget命令，因为这行太长，我们将其分为了两行。

```
$ cd ~                      # or use another directory of your choice.  
$ wget \http://www.us.apache.org/dist/hadoop/common/hadoop-0.20.2/hadoop-0.20.2.tar.gz  
\$ tar -xzf hadoop-0.20.2.tar.gz  
\$ sudo echo "export HADOOP\_HOME=\$PWD/hadoop-0.20.2" > /etc/profile.d/ hadoop.sh  
\$ sudo echo "PATH=\$PATH:\$HADOOP\_HOME/bin" >> /etc/profile.d/hadoop.sh  
\$ . /etc/profile
```

对于Mac OS X系统，可以通过执行如下命令来安装Hadoop。注意：对于curl命令，因为这行太长，我们将其分为了两行。

```
$ cd ~                      # or use another directory of your choice.  
$ curl -o \http://www.us.apache.org/dist/hadoop/common/hadoop-0.20.2/hadoop-0.20.2.tar.gz  
\$ tar -xzf hadoop-0.20.2.tar.gz  
\$ echo "export HADOOP\_HOME=\$PWD/hadoop-0.20.2" >> \$HOME/.bashrc  
\$ echo "PATH=\$PATH:\$HADOOP\_HOME/bin" >> \$HOME/.bashrc  
\$ . \$HOME/.bashrc
```

在下文中，我们将假设用户，像上面的命令一样，已经将\$HADOOP_HOME/bin加入到环境变量路径中了。这样设置后用户只需要输入hadoop命令即可，无需加上路径前缀。

2.2.3 本地模式、伪分布式模式和分布式模式

在继续讲解之前，我们先阐明Hadoop的不同运行模式。我们前面提到默认的模式是本地模式，这种模式下使用的是本地文件系统。在本地模式下，当执行Hadoop job时（包含有大多数的Hive查询），Map task和Reduce task在同一个进程中执行。

真实的集群配置的都是分布式模式，其中所有没有完整URL指定的路径默认都是分布式文件系统（通常是HDFS）中的路径，而且由*JobTracker*服务来管理job，不同的task在不同的进程中执行。

对于在个人计算机上工作的开发者来说，一个进退两难的实际问题是，本地模式并不能真实地反映真实集群的行为状况，这个是测试程序时需要记住的事情。为了解决这个需求，一台物理机可以配置成在伪分布式模式下执行。这种模式下执行的行为和在分布式模式下的行为是一致的。也就是说，引用的文件系统默认为分布式文件系统，而且由*JobTracker*服务来管理job，但是实际上只有一台物理机。因此，例如，HDFS文件块冗余数这时限制为一个备份。换句话说，行为类似于只有一个节点的“集群”。在第2.5节“配置Hadoop环境”中我们会讨论这些配置项。

因为Hive中大多数工作是使用Hadoop的job，所有Hive的行为可以反映出用户所使用的Hadoop运行模式。不过，即使在分布式模式下执行，Hive还是可以在提交查询前判断是否可以使用本地模式来执行这个查询。这时它会读取数据文件，然后自己管理MapReduce task，最终提供更快的执行方式。不过，对于Hadoop来说，不同模式之间的差异相对于部署方式更多地在于执行方式上。

本书中大部分情况下，不会关心用户使用的是哪种模式。我们将假定用户是以本地模式在个人计算机上工作的，而且我们将讨论这个模式所影响的情况。



提示

当处理小数据集时，使用本地模式执行可以使Hive执行得更快些。设置如下这个属性`sethive.exec.mode.local.auto=true`时，将

会触发Hive更主动地使用这种模式，即使当前用户是在分布式模式或伪分布式模式下执行Hadoop的。如果想默认使用这个配置，可以将这个命令加到\$HOME/.hiverc文件中（参考第2.7.5“.hiverc文件”章节）。

2.2.4 测试Hadoop

假设用户使用的是本地模式，我们通过两种不同方式来看看本地文件系统。下面这个是通过Linux ls命令查看Linux系统“root”目录下的目录信息：

```
$ ls /
bin  cgroup  etc  lib    lost+found  mnt    opt  root  selinux  sys  user  var
boot dev      home lib64  media      null  proc  sbin  srv      tmp  usr
```

Hadoop本身提供了一个dfs工具，这个工具可以提供对当前默认文件系统的基本文件的操作，例如ls命令。因为现在我们使用的是本地模式，所以当前默认的文件系统是本地文件系统^[6]。

```
$ hadoop dfs -ls /
Found 26 items
drwxrwxrwx - root root      24576 2012-06-03 14:28 /tmp
drwxr-xr-x - root root      4096 2012-01-25 22:43 /opt
drwx----- - root root     16384 2010-12-30 14:56 /lost+found
drwxr-xr-x - root root          0 2012-05-11 16:44 /selinux
dr-xr-x--- - root root     4096 2012-05-23 22:32 /root
...
```

如果用户遇到错误信息提示“没有发现命令hadoop”，那么可以通过直接指定绝对路径来执行这个命令（例如，\$HOME/hadoop-0.20.2/bin/hadoop），或者将bin目录加载到PATH环境变量中，这个在前面第2.2.2节“安装Hadoop”中讨论过了。



提示

当你发现需要频繁地使用hadoop dfs命令时，最好为这个命令定义一个别名（例如，alias hdfs="hadoop dfs"）。

Hadoop提供了MapReduce计算框架。Hadoop分支中都会包含有一个Word Count算法实现，这个我们在第1章讨论过了。现在，我们来运

行它！

首先我们要创建一个输入目录（要位于用户当前工作目录内）用于存放将要使用Hadoop进行处理的文件：

```
$ mkdir wc-in
$ echo "bla bla" > wc-in/a.txt
$ echo "bla wa wa " > wc-in/b.txt
```

使用hadoop命令指定我们刚刚创建好的文件输入目录来执行Word Count程序。需要注意的是，最好每次指定的文件输入和输出路径都是文件夹，而不是文件。这是因为通常输入和（或）输出目录中都有很多的文件，这是系统并行性的结果。

如果用户是在本地安装的软件上以本地模式运行这些命令的话，那么hadoop命令将会在同一个进程中加装MapReduce组件。如果用户是在集群中运行或者使用伪分布式模式在单台机器上执行的话，那么hadoop命令将会使用JobTracker服务启动一个或者多个不同的进程（也因此如下命令的输出也将是有些差异的）。同时，如果用户使用了和例子中版本不同的Hadoop的话，那么需要根据情况修改一下这个examples.jar的名字。

```
$ hadoop jar $HADOOP_HOME/hadoop-0.20.2-examples.jar wordcount wc-in wc-out
12/06/03 15:40:26 INFO input.FileInputFormat: Total input paths to process : 2
...
12/06/03 15:40:27 INFO mapred.JobClient: Running job: job_local_0001
12/06/03 15:40:30 INFO mapred.JobClient: map 100% reduce 0%
12/06/03 15:40:41 INFO mapred.JobClient: map 100% reduce 100%
12/06/03 15:40:41 INFO mapred.JobClient: Job complete: job_local_0001
```

这个Word Count程序的输出结果可以使用本地文件系统的命令进行查看：

```
$ ls wc-out/*
part-r-00000
$ cat wc-out/*
bla      3
wa      2
```

同时也可以等价的dfs命令进行查看（这是因为，我们假定是以本地模式执行的）：

```
$ hadoop dfs -cat wc-out/*
bla      3
```



提示

对于非常大的文件，当你只想查询其开始或者结尾部分信息时，这里没有提供`-moew`，`-head`或者`-tail`子命令。替代方式是，将`-cat`命令的输出通过管道传递给shell中的`more`、`head`或者`tail`命令，例如，`hadoop dfs -cat wc-out/* | more`。

注意了我们已经安装了一个Hadoop并且对其进行测试了，下面我们来安装Hive。

2.2.5 安装Hive

安装Hive的过程和安装Hadoop的过程非常相似。我们需要先下载一个Hive软件压缩包，然后进行解压缩。通常这个压缩包内不会包含有某个版本的Hadoop。一个Hive二进制包可以在多个版本的Hadoop上工作。这也意味着和Hadoop版本升级相比，升级Hive到新的版本会更加容易和低风险。

Hive使用环境变量`HADOOP_HOME`来指定Hadoop的所有相关JAR和配置文件。因此，在继续进行之前请确认下是否设置好了这个环境变量，这个我们之前有讨论过的。如下命令在Linux和Mac OS X系统中都可以执行。

```
$ cd ~      # or use another directory of your choice.  
$ curl -o http://archive.apache.org/dist/hive/hive-0.9.0/hive-0.9.0-bin.tar.gz  
$ tar -xzf hive-0.9.0.tar.gz  
$ sudo mkdir -p /user/hive/warehouse  
$ sudo chmod a+rwx /user/hive/warehouse
```

正如用户可以从这些命令推断到的，我们使用的是编写本书时最新最稳定的Hive发行版，也就是v0.9.0版本。不过，本书中大多数的资料也都是可以在Hive v0.7.*和Hive v0.8.*版本上执行的。当我们碰到这些资源的时候，我们会讲述它们之间有何差异。

用户可能需要将`hive`命令加入到环境变量路径中去，正如前面我们对`hadoop`进行的处理一样。我们将采用同样的方式，首先定义一个

`HIVE_HOME`变量，但是和`HADOOP_HOME`不同的是，这个变量并非是必须要定义的。本书中某些例子中我们是假定已经定义了这个变量的。

对应Linux系统，执行这些命令：

```
$ sudo echo "export HIVE_HOME=$PWD/hive-0.9.0" > /etc/profile.d/hive.sh
$ sudo echo "PATH=$PATH:$HIVE_HOME/bin" >> /etc/profile.d/hive.sh
$ . /etc/profile
```

对应Mac OS X系统，执行这些命令：

```
$ echo "export HIVE_HOME=$PWD/hive-0.9.0" >> $HOME/.bashrc
$ echo "PATH=$PATH:$HIVE_HOME/bin" >> $HOME/.bashrc
$ . $HOME/.bashrc
```

2.3 Hive内部是什么

Hive二进制分支版本核心包含3个部分。主要部分是Java代码本身。在`$HIVE_HOME/lib`目录下可以发现有众多的JAR（Java压缩包）文件，例如`hive-exec*.jar`和`hive-metastore*.jar`。每个JAR文件都实现了Hive功能中某个特定的部分，具体详情我们现在无需关心。

`$HIVE_HOME/bin`目录下包含可以执行各种各样Hive服务的可执行文件，包括`hive`命令行界面（也就是CLI）。CLI是我们使用Hive的最常用方式。除非有特别说明，否则我们都使用`hive`（小写，固定宽度的字体）来代表CLI。CLI可用于提供交互式的界面供输入语句或者可以供用户执行含有Hive语句的“脚本”，这个我们后面会有介绍。

Hive还有一些其他组件。Thrift服务提供了可远程访问其他进程的功能，也提供使用JDBC和ODBC访问Hive的功能。这些都是基于Thrift服务实现的。在后面的多章内容中我们将讲述这些功能。

所有的Hive客户端都需要一个metastoreservice（元数据服务），Hive使用这个服务来存储表模式信息和其他元数据信息。通常情况下会使用一个关系型数据库中的表来存储这些信息。默认情况下，Hive会使用内置的Derby SQL服务器，其可以提供有限的、单进程的存储服务。例如，当使用Derby时，用户不可以执行2个并发的Hive CLI实例，然而，如果是在个人计算机上或者某些开发任务上使用的话这样也是

没问题的。对于集群来说，需要使用MySQL或者类似的关系型数据库。第2.5.3节“使用JDBC连接元数据”中我们将详细讨论。

最后，Hive还提供了一个简单的网页界面，也就是Hive网页界面(HWI)，提供了远程访问Hive的服务。

conf目录下存放了配置Hive的配置文件。Hive具有非常多的配置属性，根据需要后面我们会进行介绍。这些属性控制的功能包括元数据存储（如数据存放在哪里）、各种各样的优化和“安全控制”，等等。

2.4 启动Hive

终于我们可以从Hive命令行界面(CLI)开始执行一些命令了！我们会简要地说明一下出现了什么情况，而在后面才会进行详尽的讨论。

在后面的会话中，我们将使用\$HIVE_HOME/bin/hive命令，这是个bash shell脚本，用于启动CLI。下面脚本中出现的\$HIVE_HOME可以根据需要替换为用户的Hive安装目录路径。如果用户已经将\$HIVE_HOME/bin加入到环境变量PATH中了，那么只需要输入hive就可以执行命令了。本书的后续部分将假定用户已经加入到环境变量中了。

和以前一样，\$是bash提示符。在Hive CLI中，字符串hive>是Hive的提示符，而大于号>是第2个提示符。这里有个样例会话，为清晰表达，我们在每个命令后面都人为地增加了一个空行：

```
$ cd $ HIVE_HOME
$ bin/hive
Hive history file=/tmp/myname/hive_job_log_myname_201201271126_1992326118. txt
hive> CREATE TABLE x (a INT);
OK
Time taken: 3.543 seconds

hive> SELECT * FROM x;
OK
Time taken: 0.231 seconds

hive> SELECT *
      > FROM x;
OK
Time taken: 0.072 seconds

hive> DROP TABLE x;
```

```
OK
Time taken: 0.834 seconds

hive> exit;
$
```

CLI所打印出的第1行显示的是CLI将关于用户所执行的命令和查询的日志数据所存放在的本地文件系统中的位置。如果一个命令或者查询执行成功了，那么输出中的第1行将是OK，然后才会紧跟着输出内容，最后以一行表示命令或者查询执行所消耗的时间的输出信息结尾。



提示

贯穿本书，我们将按照SQL惯例使用大写字母显示Hive的关键字（例如，CREATE, TABLE, SELECT 和FROM），尽管在Hive中关键字是大小写无关的，这也和SQL的惯例是一致的。

在后面，对于所有的会话我们通常都会在命令的输出后面加上空行。同时，在启动一个会话的时候，我们也将省略掉那行关于日志文件所在位置的输出。对于单个命令或者查询，除非在特别的情况下（例如当我们期望强调某个命令或者查询执行成功，但是其又没有其他输出信息时），否则我们也将省略掉“OK”和“Time taken:...”这些行信息。

通过上面一系列连续的提示符，我们创建了一个简单的表，表名是x，包含有一个名为a的INT（4字节整型）类型字段，然后对这个表查询了2次，第2次查询是为了显示查询语句和命令，可以多行输入。最后，我们删除了这个表。

如果用户使用默认的Derby数据库作为元数据存储的话，那么这时可以注意到在用户当前工作目录下新出现了一个名为`metastore_db`的目录，这个目录是在启动Hive会话时由Derby创建的。如果用户使用的是之前所介绍的虚拟机（VM），由于其配置可能不同，就会使得其行为也可能是不同的，这个我们后面会做讨论。

在用户所在的任意工作目录下都创建一个名为`metastore_db`的子目录并不方便，因为当用户切换到新的工作目录下时，Derby会“忘记”在

前一个目录下的元数据存储信息！在下一节中，我们将讨论如何为元数据存储数据库配置一个永久的路径，同时还会做其他一些调整。

2.5 配置Hadoop环境

下面我们稍微深入地看看Hadoop的不同模式并讨论和Hive相关的更多配置问题。

如果用户正在一个已经存在的集群中使用Hadoop或者是使用一个虚拟机实例的话，那么可以跳过本节。如果你是一个开发者或者你自己安装Hadoop和Hive的，你将会对本节后面的内容感兴趣。不过，我们不会提供一个完整的讨论。参考 [附录A “Hadoop: The Definitive Guide by Tom White”](#) 来查看不同模式下的详细配置。

2.5.1 本地模式配置

回想下，在本地模式中，所有提及的文件都存储在本地文件系统而不是分布式文件系统中。其中没有服务在运行。相反地，用户的job在同一个JVM实例中执行所有的任务。

下面图2-1 阐明了在本地模式下执行Hadoop job的过程。

Word Count 程序调用过程

```
hadoop jar hadoop-examples.jar \
wordcount /home/edward/a \
/home/edward/out/
```




图2-1 本地模式下的Hadoop

如果用户计划经常使用本地模式的话，那么非常有必要为Derby metastore_db（这里Hive存储了用户的表等元数据信息）配置一个标准的位置。

用户如果不使用默认的路径，那么还可以配置一个不同的目录来存储表数据。对于本地模式，默认路径是file:///user/hive/warehouse，对于其他模式，默认存储路径是hdfs://namenode_server/user/hive/warehouse。

首先，切换到\$HIVE_HOME/conf目录下。好奇者可能会看到hive-default.xml.template这个大文件。这个文件中包含了Hive提供的配置属性以及默认的属性值。这些属性中的绝大多数，用户可以直接忽略不管。用户所作的配置修改只需要在hive-site.xml文件中进行就可以了。如果这个文件不存在，那么用户需要自己创建一个。

这里有个配置文件样例，其为本地模式执行配置了几个属性（见例2-1）。

例2-1 本地模式下的hive-site.xml配置文件。

```
<?xml version="1.0"?>
<?xml-stylesheet type="text/xsl" href="configuration.xsl"?>
<configuration>
  <property>
    <name>hive.metastore.warehouse.dir</name>
    <value>/home/me/hive/warehouse</value>
    <description>
      Local or HDFS directory where Hive keeps table contents.
    </description>
  </property>
  <property>
    <name>hive.metastore.local</name>
    <value>true</value>
    <description>
      Use false if a production metastore server is used.
    </description>
  </property>
  <property>
    <name>javax.jdo.option.ConnectionURL</name>
    <value>jdbc:derby:/home/me/hive/metastore_db;create=true</value>
    <description>
      The JDBC connection URL.
    </description>
  </property>
</configuration>
```

用户可以根据需要从配置文件中移除掉某些不需要改变的属性，也就是<property>...</property>标签包含的内容。

正如<description>标签内所表明的，属性hive.metastore.warehouse.dir告诉Hive在本地文件系统中使用哪个路径来存储Hive表中的数据。（这个值会追加到Hadoop配置文件中所配置的属性fs.default.name的值，其默认为file:///。）用户可以根据需要为这个属性指定任意的目录路径。

属性hive.metastore.local的默认值就是true，因此在例2-1中我们其实是没必要将这个属性加进去的。放在例子中更多的目的是提供文档信息。这个属性控制着是否连接到一个远程metastore server或者是否作为Hive Client JVM的构成部分重新打开一个新的metastore server。这个设置通常是设置成true的，然后使用JDBC直接和一个关系型数据库通信。当设置为false时，Hive将会通过一个metastore server来进行通信，这个我们将在第16.8节“metastore方法”中进行讨论。

属性javax.jdo.option.ConnectionURL的值对默认的值进行了简单的修改。这个属性告诉Hive如何连接metastore server。默认情况下，它使用当前的工作目录作为属性值字符串中的databaseName部分。如例 2-1 中所示，我们使用databaseName=/home/me/hive/metastore_db作为绝对路径，它是metastore_db目录所在的路径。这样设置可以解决每次开启一个新的Hive会话时，Hive自动删除工作目录下的metastore_db目录的问题。现在，我们不管在哪个目录下工作都可以访问到所有的元数据。

2.5.2 分布式模式和伪分布式模式配置

在分布式模式下，集群中会启动多个服务。JobTracker管理着job，而HDFS则由NameNode管理着。每个工作节点上都有job task在执行，由每个节点上的TaskTracker服务管理着；而且每个节点上还存放有分布式文件系统中的文件数据块，由每个节点上的DataNode服务管理着。

图2-2展示了Hadoop集群的一个典型的分布式模式配置。




图2-2 分布式模式下的Hadoop

我们约定对于集群的内外网，使用*.domain.pvt作为我们的DNS命名规范。

伪分布式模式也几乎是相同的，事实上它就是一个单节点的集群。

我们假定用户的管理员已经配置好了Hadoop，包括分布式文件系统（例如，HDFS，或者请参考附录A *Hadoop: The Definitive Guide* by Tom White）。因此，我们将关注其与Hive所要求的不同的配置过程。

用户可能需要配置的一个Hive属性是表存储所位于的顶级文件目录，其由属性hive.metastore.warehouse.dir指定，在第2.5.1节“本地模式配置”中也有进行讨论。

Apache Hadoop和MapR分支中这个属性的默认值是`/user/hive/warehouse`，当Hadoop配置的是分布式模式或者伪分布式模式时，这个路径被认为是分布式文件系统中的路径。对于Amazon弹性MapReduce系统（EMR），当使用Hivev0.M.N版本时，这个属性的默认值是`/mnt/hive_0M_N/warehouse`（例如，`/mnt/hive_08_1/warehouse`）。

为这个属性指定不同的值可以允许每个用户定义其自己的数据仓库目录，这样就可以避免影响其他系统用户。因此，用户可能需要使用如下语句来为自己的指定数据仓库目录：

```
set hive.metastore.warehouse.dir=/user/myname/hive/warehouse;
```

如果每次启动Hive CLI或者在每个Hive脚本前都指定这行语句，那么显得过于冗长。当然，也更容易会忘记设置这个属性值。因此，最好将和这个命令类似的所有命令放置在`$HOME/.hiverc`文件中，每一次启动Hive都会执行这个文件。参考第2.7.5节“`hive`rc文件”获得更详细信息。

由此处开始我们将假定值是`/user/hive/warehouse`。

2.5.3 使用JDBC连接元数据

Hive所需要的组件中只有一个外部组件是Hadoop没有的，那就是`metastore`（元数据存储）组件。元数据存储中存储了如表的模式和分区信息等元数据信息。用户在执行如`create table x...`或者`alter table y...`等命令时会指定这些信息。因为多用户和系统可能需要并发访问元数据存储，所以默认的内置数据库并不适用于生产环境。



提示

如果用户使用的是单个节点上的伪分布式模式，那么用户可能会发现，为元数据存储设置一个完整的关系型数据库并没多大用处，反而，用户可能希望继续使用默认的`Derby`进行元数据存储，但是可以为其设置一个中央位置来储存数据，这个在第2.5.1节“本地模式配置”中已经讨论过了。

任何一个适用JDBC进行连接的数据库都可用作元数据存储。在实践中，大多数的Hive客户端会使用MySQL。我们也将讨论如何使用MySQL来进行元数据存储。执行过程对于其他适用于JDBC连接的数据库都是适用的。



提示

像表的模式信息、分区信息等这些必须的元数据，其信息量是很小的，通常比存储在Hive中的数据的量要少的多。因此，用户其实无需为元数据存储提供一个强劲的专用数据库服务器。不过，因为这是一个单点问题（SPOF），所以强烈建议用户使用对于其他关系型数据库实例同样适用的标准技术来对这个数据库进行冗余存储和数据备份。这里我们不会探讨这些技术。

对于MySQL配置，我们需要知道指定服务运行在哪个服务器和端口。我们将假定是在db1.mydomain.pvt服务器的3306端口上，这个端口也是标准的MySQL端口。最后，我们假定存储数据库名为hive_db。我们在例2-2中定义了这些属性。

例2-2 hive-site.xml中的元数据存储数据库配置。

```
<?xml version="1.0"?>
<?xml-stylesheet type="text/xsl" href="configuration.xsl"?>
<configuration>
  <property>
    <name>javax.jdo.option.ConnectionURL</name>
    <value>jdbc:mysql://db1.mydomain.pvt/hive_db?
createDatabaseIfNotExist=true</value>
  </property>
  <property>
    <name>javax.jdo.option.ConnectionDriverName</name>
    <value>com.mysql.jdbc.Driver</value>
  </property>
  <property>
    <name>javax.jdo.option.ConnectionUserName</name>
    <value>database_user</value>
  </property>
  <property>
    <name>javax.jdo.option.ConnectionPassword</name>
    <value>database_pass</value>
  </property>
</configuration>
```

用户可能已经注意到ConnectionURL属性值前缀是jdbc:mysql。

为了使Hive能够连接上MySQL，我们需要将JDBC驱动放置在类路径下。MySQL JDBC驱动（Jconnector）可以从如下网址下载：

<http://www.mysql.com/downloads/connector/j/>。这个驱动可以放置在Hive的库路径下，也就是\$HIVE_HOME/lib目录下。有些团队会将所有这些支持类的库放置在Hadoop的库目录下。

驱动和配置设置正确后，Hive就会将元数据信息存储到MySQL中。

2.6 Hive命令

\$HIVE_HOME/bin/hive这个shell命令（后面我们省略称为hive）是通向包括命令行界面也就是CLI等Hive服务的通道。

我们假定用户已经将\$HIVE_HOME/bin加入到环境变量PATH中了，则用户只需要在shell提示符中输入hive，就可以使用用户的shell环境（例如bash环境）找到这个命令。

命令选项

如果用户执行下面的命令，那么可以查看到hive命令的一个简明说明的选项列表。下面是Hive v0.8.*和Hive v0.9.*系列版本的输出：

```
$ bin/hive --help
Usage ./hive <parameters> --service serviceName <service parameters>
Service List: cli help hiveserver hwi jar lineage metastore rcflecat
Parameters parsed:
  --auxpath : Auxiliary jars
  --config : Hive configuration directory
  --service : Starts specific service/component. cli is default
Parameters used:
  HADOOP_HOME : Hadoop install directory
  HIVE_OPT : Hive options
For help on a particular service:
  ./hive --service serviceName --help
Debug help: ./hive --debug --help
```

需要注意*Service List*后面的内容。这里提供了几个服务，包括我们绝大多数时间将要使用的CLI。用户可以通过--service name服务名称来启用某个服务，尽管其中有几个服务也是有快捷启动方式的。

表2-2中描述了最有用的服务。

表2-2 Hive服务

选项	名称	描述
cli	命令行界面	用户定义表，执行查询等。如果没有指定其他服务，这个是默认的服务。参考第2.7节“命令行界面”
hiveserver	Hive Server	监听来自于其他进程的Thrift连接的一个守护进程
hwi	Hive Web界面	是一个可以执行查询语句和其他命令的简单的Web界面，这样可以不用登录到集群中的某台机器上使用CLI来进行查询
jar		hadoop jar命令的一个扩展，这样可以执行需要Hive环境的应用
metastore		启动一个扩展的Hive 元数据服务，可以供多客户端使用（参考第2.5.3节“使用JDBC连接元数据”）
rcfilecat		一个可以打印出RCFile格式（参考第15.3.2节“RCFile”）文件内容的工具

--auxpath选项允许用户指定一个以冒号分割的“附属的”Java包（JAR），这些文件中包含有用户可能需要的自定义扩展等。

--config文件目录这个命令允许用户覆盖\$HIVE_HOME/conf中默认的属性配置，而指向一个新的配置文件目录。

2.7 命令行界面

命令行界面，也就是CLI，是和Hive交互的最常用的方式。使用CLI，用户可以创建表，检查模式以及查询表，等等。

2.7.1 CLI 选项

下面这个命令显示了CLI所提供的选项列表。这里显示的是Hive v0.8.* 和Hive v0.9.*版本的输出：

```
$ hive --help --service cli
usage: hive
  -d,--define <key=value>      Variable substitution to apply to hive
                                commands. e.g. -d A=B or --define A=B
  -e <quoted-query-string>    SQL from command line
  -f <filename>                SQL from files
  -H,--help                     Print help information
  -h <hostname>                connecting to Hive Server on remote host
  --hiveconf <property=value>   Use value for given property
  --hivevar <key=value>         Variable substitution to apply to hive
                                commands. e.g. --hivevar A=B
  -i <filename>                Initialization SQL file
  -p <port>                     connecting to Hive Server on port number
  -S,--silent                   Silent mode in interactive shell
  -v,--verbose                  Verbose mode (echo executed SQL to the
                                console)
```

这个命令的一个简化版表示方式是hive -h。然而从技术上来说并不支持这个选项。这个命令会输出帮助信息，同时还输出一条提示信息提示“选项h缺少参数”。

对于Hive v0.7.*版本，不支持-d、--hivevar和-p选项。

下面我们来更详细地探讨这些选项。

2.7.2 变量和属性

--define key=value实际上和--hivevar key=value是等价的。二者都可以让用户在命令行定义用户自定义变量以便在Hive脚本中引用，来满足不同情况的执行。这个功能只有Hive v0.8.0版本和之后的版本才支持。

当用户使用这个功能时，Hive会将这些键-值对放到hivevar命名空间，这样可以和其他3种内置命名空间（也就是hiveconf、system和env），进行区分。



提示

变量或者属性是在不同的上下文中使用的术语，但是在大多数情况下它们的功能是相同的。

表2-3描述了命名空间选项。

表2-3 Hive中变量和属性命名空间

命名空间	使用权限	描述
hivevar	可读/可写	(Hive v0.8.0以及之后版本) 用户自定义变量
hiveconf	可读/可写	Hive相关的配置属性
system	可读/可写	Java定义的配置属性
env	只可读	Shell环境 (例如bash) 定义的环境变量

Hive变量内部是以Java字符串的方式存储的。用户可以在查询中引用变量。Hive会先使用变量值替换掉查询的变量引用，然后才会将查询语句提交给查询处理器。

在CLI中，可以使用SET命令显示或者修改变量值。例如，下面这个会话先显示一个变量的值，然后再显示env命名空间中定义的所有变量！为了更清晰地表现，我们省略掉了这个Hive会话中的一些输出信息，而且在每行命令之间人为地增加了一个空白行：

```
$ hive
hive>set env:HOME;
env:HOME=/home/thisuser

hive>set;
... 非常多的输出信息，而且包含有下面这些变量的:
hive.stats.retries.wait=3000
env:TERM=xterm
system:user.timezone=America/New_York
...

hive>set -v;
... 更多的输出信息!...
```

如果不加-v标记，`set`命令会打印出命名空间`hivevar`，`hiveconf`，`system`和`env`中所有的变量。使用-v标记，则还会打印Hadoop中所定义的所有属性，例如控制HDFS和MapReduce的属性。

`set`命令还可用于给变量赋新的值。我们特别看下`hivevar`命名空间以及如何通过命令行定义一个变量：

```
$ hive --define foo=bar
hive> set foo;
foo=bar;

hive> set hivevar:foo;
hivevar:foo=bar;

hive> set hivevar:foo=bar2;
hive> set foo;
foo=bar2

hive> set hivevar:foo;
hivevar:foo=bar2
```

我们可以看到，前缀`hivevar:`是可选的。`--hivevar`标记和`--define`标记是相同的。

在CLI中查询语句中的变量引用会先被替换掉然后才会提交给查询处理器。思考如下这个CLI会话（在v0.8.*版本中使用）：

```
hive> create table toss1(i int, ${hivevar:foo} string);
hive> describe toss1;
i          int
bar2      string

hive> create table toss2(i2 int, ${foo} string);

hive> describe toss2;
i2          int
bar2      string

hive> drop table toss1;
hive> drop table toss2;
```

我们来看看`--hiveconf`选项，Hive v0.7.*版本支持这个功能，其用于配置Hive行为的所有属性。我们用它来指定Hive v0.8.0版本中增加的`hive.cli.print.current.db`属性。开启这个属性可以在CLI提示符前打印出当前所在的数据库名（第4.1节“Hive中的数据库”中有关于Hive数据库的更多信息），默认的数据库名为`default`。这个属性的默认值是`false`。

```
$ hive --hiveconf hive.cli.print.current.db=true
hive (default)> set hive.cli.print.current.db;
hive.cli.print.current.db=true

hive (default)> set hiveconf:hive.cli.print.current.db;
hiveconf:hive.cli.print.current.db=true

hive (default)> set hiveconf:hive.cli.print.current.db=false;

hive> set hiveconf:hive.cli.print.current.db=true;

hive (default)> ...
```

我们甚至可以增加新的hiveconf属性，这个功能只有Hive v0.8.0版本前的版本才支持：

```
$ hive --hiveconf y=5
hive> set y;
y=5

hive> CREATE TABLE whatsit(i int);

hive> ... 装载数据到表whatsit中 ...

hive> SELECT * FROM whatsit WHERE i = ${hiveconf:y};
...
```

我们还有必要了解一下system命名空间，Java系统属性对这个命名空间内容具有可读可写权利；而env命名空间，对于环境变量只提供可读权限：

```
hive> set system:user.name;
system:user.name=myusername

hive> set system:user.name=yourusername;

hive> set system:user.name;
system:user.name=yourusername

hive> set env:HOME;
env:HOME=/home/yourusername

hive> set env:HOME;
env: * variables can not be set.
```

和hivevar变量不同，用户必须使用system:或者env:前缀来指定系统属性和环境变量。

env命名空间可作为向Hive传递变量的一个可选的方式，特别是对于Hive v0.7.*版本。考虑如下这个例子：

```
$ YEAR=2012 hive -e "SELECT * FROM mytable WHERE year = ${env:YEAR}";
```

查询处理器会在WHERE子句中查看到实际的变量值2012。



警告

如果你现在使用的是Hive v0.7.*版本，那么这本书中一些使用参数和变量的例子和写的可能并不符合。如果有这种情况，那么将变量替换成具体的值即可。



提示

Hive中所有的内置属性都在\$HIVE_HOME/conf/hivedefault.xml.template中列举出来了，这是一个“样例”配置文件。配置文件中还说明了这些属性的默认值。

2.7.3 Hive中“一次使用”命令

用户可能有时期望执行一个或者多个查询（使用分号分隔），执行结束后hive CLI立即退出。Hive提供了这样的功能，因为CLI可以接受-e命令这种形式。如果表mytable具有一个字符串字段和一个整型字段，我们可以看到如下输出：

```
$ hive -e "SELECT * FROM mytable LIMIT 3";
OK
name1 10
name2 20
name3 30
Time taken: 4.955 seconds
$
```

临时应急时可以使用这个功能将查询结果保存到一个文件中。增加-S选项可以开启静默模式，这样可以在输出结果中去掉“OK”和“Time taken”等行，以及其他一些无关紧要的输出信息，如下面这个例子：

```
$ hive -S -e "select * FROM mytable LIMIT 3" > /tmp/myquery
$ cat /tmp/myquery
name1 10
name2 20
name3 30
```

需要注意的是，Hive会将输出写到标准输出中。上面例子中的shell命令将输出重定向到本地文件系统中，而不是HDFS中。

最后，当用户不能完整记清楚某个属性名时，可以使用下面这个非常有用的技巧来模糊获取这个属性名而无需滚动set命令的输出结果进行查找。假设用户没记清哪个属性指定了管理表的“warehouse(数据仓库)”的路径，通过如下命令可以查看到：

```
$ hive -S -e "set" | grep warehouse
hive.metastore.warehouse.dir=/user/hive/warehouse
hive.warehouse.subdir.inherit.perms=false
```

这是第一种情况。

2.7.4 从文件中执行Hive查询

Hive中可以使用-f文件名方式执行指定文件中的一个或者多个查询语句。按照惯例，一般把这些Hive查询文件保存为具有.q或者.hql后缀名的文件。

```
$ hive -f /path/to/file/withqueries.hql
```

在Hive shell中用户可以使用SOURCE命令来执行一个脚本文件。下面是一个例子：

```
$ cat /path/to/file/withqueries.hql
SELECT x.* FROM src x;
$ hive
hive> source /path/to/file/withqueries.hql;
...
```

顺便说一下，如果查询中的表名和这个例子并不相关，我们有时会使用src（代表“源表”）作为表名。这个约定来源于Hive源码中的单元测试中的写法。它会在所有测试开始前先创建一个名为src的表。

例如，在试用某个内置函数时，通常会写个“查询”语句，然后往这个函数中传入参数，如下面这个例子所示（这个例子在第15.9节《XPath相关的函数》中会讲到）：

```
hive> SELECT xpath('\''<a><b id="foo">b1</b><b id="bar">b2</b></a>\',\'//@id\'')
   > FROM src LIMIT 1;
[foo", "bar"]
```

我们现在不必关心xpath的细节问题，但是需要注意，我们向xpath中传递了2个字符串类型的参数，而且使用了FROM src LIMIT 1来指定必须要有的FROM子句，并限制了输出行数。src代表一个已经创建好的或者虚拟地创建了的名为src的表：

```
CREATE TABLE src(s STRING);
```

同时必须至少有一行的数据在源表里面：

```
$ echo "one row" > /tmp/myfile
$ hive -e "LOAD DATA LOCAL INPATH '/tmp/myfile' INTO TABLE src;"
```

2.7.5 hiverc文件

我们最后将要讨论的CLI选项是 -i 文件名。这个选项允许用户指定一个文件，当CLI启动时，在提示符出现前会先执行这个文件。Hive会自动在HOME目录下寻找名为.hiverc的文件，而且会自动执行这个文件中的命令（如果文件中有的话）。

对于用户需要频繁执行的命令，使用这个文件是非常方便的。例如设置系统属性（参考第2.7.2节“变量和属性”），或者增加对于Hadoop的分布式内存（在第15章将会有介绍）进行自定义的Hive扩展的Java包（JAR文件）。

下面的例子显示的是一个典型的\$HOME/.hiverc文件中的内容：

```
ADD JAR /path/to/custom_hive_extensions.jar;
set hive.cli.print.current.db=true;
set hive.exec.mode.local.auto=true;
```

上面例子第1行表示向Hadoop分布式内存中增加一个JAR文件。第2行表示修改CLI提示符前显示当前所在的工作数据库，这个我们在前

面第2.7.2节“变量和属性”中讲述过了。最后1行表示“鼓励”Hive如果可以使用本地模式执行（即使当Hadoop是以分布式模式或伪分布式模式执行时）的话就在本地执行，这样可以加快小数据集的数据查询速度。



警告

一个比较容易犯的错误就是忘记在每行的结尾加逗号。如果用户犯了这个错误，那么这个属性将包含后面几行所有的文字，直到发现下一个逗号。

2.7.6 使用Hive CLI的更多介绍

CLI支持其他一些有用的功能。

自动补全功能

如果用户在输入的过程中敲击Tab制表键，那么CLI会自动补全可能的关键字或者函数名。例如，如果用户输入SELE然后按Tab键，CLI将自动补全这个词为SELECT。

如果用户在提示符后面直接敲击Tab键，那么用户会看到如下回复：

```
hive>  
Display all 407 possibilities? (y or n)
```



警告

当向CLI中输入语句时，如果某些行是以Tab键开头的话，就会产生一个常见的令人困惑的错误。用户这时会看到一个“是否显示所有可能的情况”的提示，而且输入流后面的字符会被认为是对这个提示的回复，也因此会导致命令执行失败。

2.7.7 查看操作命令历史

用户可以使用上下箭头来滚动查看之前的命令。事实上，每一行之前的输入都是单独显示的，CLI不会把多行命令和查询作为一个单独的历史条目。Hive会将最近的100, 00行命令记录到文件\$HOME/.hivehistory中。

如果用户想再次执行之前执行过的某条命令，只需要将光标滚动到那条记录然后按Enter键就可以了。如果用户需要修改这行记录后再执行，那么需要使用左右方向键将光标移动到需要修改的地方然后重新编辑修改就可以了。修改后用户直接敲击Enter键就可以提交这条命令而无需切换到命令尾。



提示

大多数的导航按键使用的Control+字母的命令和bash shell中是相同的（例如，Control+A 代表光标移到到行首，Control+B 代表光标移动到行尾）。然而，类似的“元操作”Option或者Escape键就不起作用了（例如，Option+F一次向前移动一个单词这样的命令）。相似地，Delete删除键会删除光标左边的字符，而Forward Delete回格键不会删除掉光标当前所在的字符。

2.7.8 执行shell命令

用户不需要退出hive CLI就可以执行简单的bash shell命令。只要在命令前加上!并且以分号 (;) 结尾就可以：

```
hive> ! /bin/echo "what up dog";
"what up dog"
hive> ! pwd;
/home/me/hiveplay
```

Hive CLI中不能使用需要用户进行输入的交互式命令，而且不支持shell的“管道”功能和文件名的自动补全功能。例如，! ls *.hql; 这个命令表示的是查找文件名为*.hql;的文件，而不是表示显示以.hql结尾的所有文件。

2.7.9 在Hive内使用Hadoop的dfs命令

用户可以在Hive CLI中执行Hadoop的dfs ... 命令，只需要将hadoop命令中的关键字hadoop去掉，然后以分号结尾就可以了：

```
hive> dfs -ls / ;
Found 3 items
drwxr-xr-x    - root supergroup      0 2011-08-17 16:27 /etl
drwxr-xr-x    - edward supergroup    0 2012-01-18 15:51 /flag
drwxrwxr-x    - hadoop supergroup    0 2010-02-03 17:50 /users
```

这种使用hadoop 命令的方式实际上比与其等价的在bash shell中执行的hadoop dfs... 命令要更高效。因为后者每次都会启动一个新的JVM实例，而Hive会在同一个进程中执行这些命令。

用户可以通过如下命令查看dfs所提供的所有功能选项列表：

```
hive> dfs -help;
```

用户还可以登录网址
http://hadoop.apache.org/common/docs/r0.20.205.0/file_system_shell.html
或者是查看用户所使用的Hadoop发行版的文档来获取这些命令的说明。

2.7.10 Hive脚本中如何进行注释

对于Hive v0.8.0版本，用户可以使用以--开头的字符串来表示注释，例如：

```
-- Copyright (c) 2012 Megacorp, LLC.
-- This is the best Hive script evar!!

SELECT * FROM massive_table;
...
```



警告

CLI是不会解析这些注释行的。因此如果用户在CLI中粘贴这些注释语句，那么将会有错误信息。他们只能放在脚本中通过hive -f script_name的方式执行。

2.7.11 显示字段名称

作为最后一个例子，我们把学到的很多东西都放在了一起。我们可以让CLI打印出字段名称（这个功能默认是关闭的）。我们可以通过设置hiveconf配置项hive.cli.print.header为true来开启这个功能：

```
hive> set hive.cli.print.header=true;  
hive> SELECT * FROM system_logs LIMIT 3;  
tstamp severity server message  
1335667117.337715 ERROR server1 Hard drive hd1 is 90% full!  
1335667117.338012 WARN server1 Slow response from server2.  
1335667117.339234 WARN server2 Uh, Dude, I'm kinda busy right now...
```

如果用户希望总是看到字段名称，那么只需要将第1行添加到\$HOME/.hiverc文件中即可。

[1]<http://vmware.com>。

[2]<https://www.virtualbox.org/>。

[3]然而，一些厂商目前开始支持Hadoop在其他操作系统中使用。Hadoop目前已经在生产中应用于各种各样的UNIX操作系统上，其在Mac OS X中作开发用时效果很好。

[4]这些是写这本书时所提供的URL链接。

[5]至少这个是Dean的Mac电脑中当前的配置情况。这个差异可能实际上反映了一个事实，即：Mac OS X中Java的管理工作自Java 1.7版本开始从Apple过渡到了Oracle。

[6]不幸的是，dfs -ls命令仅提供“长列表”格式。没有像Linux系统中ls命令显示的那种简短格式。

第3章 数据类型和文件格式

Hive支持关系型数据库中的大多数基本数据类型，同时也支持关系型数据库中很少出现的3种集合数据类型，下面我们将简短地介绍一下这样做的原因。

其中一个需要考虑的因素就是这些数据类型是如何在文本文件中进行表示的，同时还要考虑文本存储中为了解决各种性能问题以及其他问题有哪些替代方案。和大多数的数据库相比，Hive具有一个独特的功能，那就是其对于数据在文件中的编码方式具有非常大的灵活性。大多数的数据库对数据具有完全的控制，这种控制既包括对数据存储到磁盘的过程的控制，也包括对数据生命周期的控制。Hive将这些方面的控制权转交给用户，以便更加容易地使用各种各样的工具来管理和处理数据。

3.1 基本数据类型

Hive支持多种不同长度的整型和浮点型数据类型，支持布尔类型，也支持无长度限制的字符串类型。Hive v0.8.0版本中增加了时间戳数据类型和二进制数组数据类型。

表3-1 列举了Hive所支持的基本数据类型。

表3-1 基本数据类型

数据类型	长度	例子
TINYINT	1byte有符号整数	20
SMALINT	2byte有符号整数	20

数据类型	长度	例子
INT	4byte有符号整数	20
BIGINT	8byte有符号整数	20
BOOLEAN	布尔类型，true或者false	TRUE
FLOAT	单精度浮点数	3.14159
DOUBLE	双精度浮点数	3.14159
STRING	字符串序列。可以指定字符集。可以使用单引号或者双引号	‘now is the time’， “for all good men”
TIMESTAMP(v0.8.0+)	整数，浮点数或者字符串	1327882394 (Unix新纪元秒) , 1327882394.123456789 (Unix新纪元秒并跟随有纳秒数) 和 '2012-02-03 12:34:56.123456789' (JDBC所兼容的java.sql.Timestamp时间格式)
BINARY(v0.8.0+)	字节数组	请看后面的讨论

和其他SQL方言一样，这些都是保留字。

需要注意的是所有的这些数据类型都是对Java中的接口的实现，因此这些类型的具体行为细节和Java中对应的类型是完全一致的。例如， STRING类型实现的是Java中的String， FLOAT实现的是Java中的float， 等等。

在其他SQL方言中，通常会提供限制最大长度的“字符数组”（也就是很多字符串）类型，但需要注意的是Hive中不支持这种数据类型。关系型数据库提供这个功能是出于性能优化的考虑。因为定长的记录更容易进行建立索引，数据扫描，等等。在Hive所处的“宽松”的世界里，不一定拥有数据文件但必须能够支持使用不同的文件格式，Hive根据不同字段间的分隔符来对其进行判断。同时，Hadoop和Hive强调优化磁盘的读和写的性能，而限制列的值的长度相对来说并不重要。

新增数据类型TIMESTAMP的值可以是整数，也就是距离Unix新纪元时间（1970年1月1日，午夜12点）的秒数；也可以是浮点数，即距离Unix新纪元时间的秒数，精确到纳秒（小数点后保留9位数）；还可以是字符串，即JDBC所约定的时间字符串格式，格式为YYYY-MM-DD hh:mm:ss.fffffffff。

TIMESTAMPS表示的是UTC时间。Hive本身提供了不同时区间互相转换的内置函数，也就是to_utc_timestamp函数和from_utc_timestamp函数(详情请查看第13章内容)。

BINARY数据类型和很多关系型数据库中的VARBINARY数据类型是类似的，但其和BLOB数据类型并不相同。因为BINARY的列是存储在记录中的，而BLOB则不同。BINARY可以在记录中包含任意字节，这样可以防止Hive尝试将其作为数字，字符串等进行解析。

需要注意的是如果用户的目标是省略掉每行记录的尾部的话，那么是无需使用BINARY数据类型的。如果一个表的表结构指定的是3列，而实际数据文件每行记录包含有5个字段的话，那么在Hive中最后2列数据将会被省略掉。

如果用户在查询中将一个float类型的列和一个double类型的列作对比或者将一种整型类型的值和另一种整型类型的值做对比，那么结果将会怎么样呢？Hive会隐式地将类型转换为两个整型类型中值较大的那个类型，也就是会将FLOAT类型转换为DOUBLE类型，而且如有必要，也会将任意的整型类型转换为DOUBLE类型，因此事实上是同类型之间的比较。

如果用户希望将一个字符串类型的列转换为数值呢？这种情况下用户可以显式地将一种数据类型转换为其他一种数据类型，后面会有

这样的一个例子，例子中s是一个字符串类型列，其值为数值：

```
...cast(s AS INT) ...;
```

(这里需要说明的是，AS INT是关键字，因此使用小写也是可以的。)

我们将会在第6.8节“类型转换”更深入地讨论数据类型转换。

3.2 集合数据类型

Hive中的列支持使用struct, map和array集合数据类型。需要注意的是表3-2中语法示例实际上调用的是内置函数。

表3-2 集合数据类型

数据类型	描述	字面语法示例
STRUCT	和C语言中的struct或者“对象”类似，都可以通过“点”符号访问元素内容。例如，如果某个列的数据类型是STRUCT{first STRING, last STRING}，那么第1个元素可以通过字段名.first来引用	struct('John', 'Doe')
MAP	MAP是一组键-值对元组集合，使用数组表示法（例如['key']）可以访问元素。例如，如果某个列的数据类型是MAP，其中键->值对是‘first’->‘John’和‘last’->‘Doe’，那么可以通过字段名['last']获取最后1个元素	map('first', 'JOIN', 'last', 'Doe')
ARRAY	数组是一组具有相同类型和名称的变量的集合。这些变量称为数组的元素，每个数组元素都有一个编号，编号从零开始。例如，数组值为[‘John’, ‘Doe’]，那么第2个元素可以通过数组名[1]进行引用	Array('John', 'Doe')

和基本数据类型一样，这些类型的名称同样是保留字。

大多数的关系型数据库并不支持这些集合数据类型，因为使用它们会趋于破坏标准格式。例如，在传统数据模型中，`structs`可能需要由多个不同的表拼装而成，表间需要适当地使用外键来进行连接。

破坏标准格式所带来的一个实际问题是会增大数据冗余的风险，进而导致消耗不必要的磁盘空间，还有可能造成数据不一致，因为当数据发生改变时冗余的拷贝数据可能无法进行相应的同步。

然而，在大数据系统中，不遵循标准格式的一个好处就是可以提供更高吞吐量的数据。当处理的数据的数量级是T或者P时，以最少的“头部寻址”来从磁盘上扫描数据是非常必要的。按数据集进行封装的话可以通过减少寻址次数来提供查询的速度。而如果根据外键关系关联的话则需要进行磁盘间的寻址操作，这样会有非常高的性能消耗。



提示

Hive中并没有键的概念。但是，用户可以对表建立索引，这些我们在第7章将会进行介绍。

这里有一个用于演示如何使用这些数据类型的表结构声明语句，这是一张虚构的人力资源应用程序中的员工表：

```
CREATE TABLE employees (
  name      STRING,
  salary    FLOAT,
  subordinates  ARRAY<STRING>,
  deductions  MAP<STRING, FLOAT>,
  address    STRUCT<street:STRING, city:STRING, state:STRING, zip:INT>);
```

其中，`name`是一个简单的字符串；对于大多数雇员来说，`salary`（薪水）使用`float`浮点数类型来表示就已经足够了；`subordinates`（下属员工）列表是一个字符串值数组。在该数组中，我们可以认为`name`是“主键”，因此`subordinates`中的每一个元素都将会引用这张表中的另一条记录。对于没有下属的雇员，这个字段对应的值就是一个空的数组。在传统的模型中，将会以另外一种方式来表示这种关系，也就是雇员和雇员的经理这种对应关系。这里我们并非强调我们的模型对于Hive来说是最好的，而只是为了举例展示如何使用数组。

字段deductions是一个由键-值对构成的map，其记录了每一次的扣除额，这些钱将会在发薪水的时候从员工工资中扣除掉。map中的键是扣除金额项目的名称（例如，“国家税收”），而且键可以是一个百分比值，也可以完全就是一个数值。在传统数据模型中，这个扣除额项目的名称（这里也就是map的键）可能存在于不同的表中。这些表在存放特定扣除额值的同时，还有一个外键指向对应的雇员记录。

最后，每名雇员的家庭住址使用struct数据类型存储，其中的每个域都被作了命名，并且具有一个特定的类型。

请注意后面是如何使用Java语法惯例来表示集合数据类型的。例如，MAP<STRING, FLOAT>表示map中的每个键都是STRING数据类型的，而每个值都是FLOAT数据类型的。对于ARRAY<STRING>，其中的每个条目都是STRING类型的。STRUCT可以混合多种不同的数据类型，但是STRUCT中一旦声明好结构，那么其位置就不可以再改变。

3.3 文本文件数据编码

下面我们一起来研究文件格式，首先举个最简单的例子，也就是文本格式文件。毫无疑问，用户应该很熟悉以逗号或者制表符分割的文本文件，也就是所谓的逗号分隔值（CSV）或者制表符分割值

（TSV）。只要用户需要，Hive是支持这些文件格式的，在后面将会介绍其具体使用方式。然而，这两种文件格式有一个共同的缺点，那就是用户需要对文本文件中那些不需要作为分隔符处理的逗号或者制表符格外小心。也因此，Hive默认使用了几个控制字符，这些字符很少出现在字段值中。Hive使用术语field来表示替换默认分隔符的字符，稍后我们将可以看到。表3-3列举了这些分隔符。

表3-3 Hive中默认的记录和字段分割符

分隔符	描述
\n	对于文本文件来说，每行都是一条记录，因此换行符可以分割记录

分隔符	描述
^A (Ctrl+A)	用于分隔字段（列）。在CREATE TABLE语句中可以使用八进制编码\001表示
^B	用于分隔ARRAY或者STRUCT中的元素，或用于MAP中键-值对之间的分隔。在CREATE TABLE语句中可以使用八进制编码\002表示
^C	用于MAP中键和值之间的分隔。在CREATE TABLE语句中可以使用八进制编码\003表示

前面章节中介绍的employees表的记录看上去和下面展示的这个例子是一样的，其中使用到了^A等字符来作为字段分隔符。像Emacs这样的文本编辑器将会以这种形式来展示这些分隔符。因为页面篇幅有限，所以每行数据并非显示在同一行。为了能较清晰地展示每行记录，我们在行与行间额外增加了一个空行：

John Doe^A100000.0^AMary Smith^BTodd Jones^AFederal Taxes^C.2^BState Taxes^C.05^BInsurance^C.1^A1 Michigan Ave.^BChicago^BIL^B60600

Mary Smith^A80000.0^ABill King^AFederal Taxes^C.2^BState Taxes^C.05^BInsurance^C.1^A100 Ontario St.^BChicago^BIL^B60601

Todd Jones^A70000.0^AFederal Taxes^C.15^BState Taxes^C.03^BInsurance^C.1^A200 Chicago Ave.^BOak Park^BIL^B60700

Bill King^A60000.0^AFederal Taxes^C.15^BState Taxes^C.03^BInsurance^C.1^A300 Obscure Dr.^BObscuria^BIL^B60100

其可读性并不好，但是当然了，我们可以使用Hive来读取这些数据。

我们先来看看第1行记录来了解一下这个结构。首先，如果使用JavaScript数据交换格式（JSON）来表示这条记录的话，那么如果增

加了額表结构中的字段名称的话，样式将会和如下所示的一样：

```
{  
  "name": "John Doe",  
  "salary": 100000.0,  
  "subordinates": ["Mary Smith", "Todd Jones"],  
  "deductions": {  
    "Federal Taxes": .2,  
    "State Taxes": .05,  
    "Insurance": .1  
  },  
  "address": {  
    "street": "1 Michigan Ave.",  
    "city": "Chicago",  
    "state": "IL",  
    "zip": 60600  
  }  
}
```

这里，用户可能会发现在JSON中map类型和struct类型其实是一样的。

那么，我们来看看文本文件的第1行分解出来的结果。

- ① John Doe对应name字段，表示用户名。
- ② 100000.0对应salary字段，表示薪水。
- ③ Mary Smith^BTodd Jones 对应subordinates字段，表示下属是“Mary Smith”和“Todd Jones”。
- ④ Federal Taxes^C.2^BState Taxes^C.05^BInsurance^C.1对应deductions字段，表示扣除的金额，其中20%用于上缴“国税”，5%用于上缴“州税”，还有10%用于上缴“保险费。”
- ⑤ 1 Michigan Ave.^BChicago^BIL^B60600对应address字段，表示住址是“芝加哥第一密歇根大道60600号。”

用户可以不使用这些默认的分隔符，而指定使用其他分隔符。当有其他应用程序使用不同的规则写数据时，这是非常必要的。下面这个表结构声明和之前的那个表是一样的，不过这里明确地指定了分隔符：

```
CREATE TABLE employees (
  name      STRING,
  salary    FLOAT,
  subordinates ARRAY<STRING>,
  deductions MAP<STRING, FLOAT>,
  address   STRUCT<street:STRING, city:STRING, state:STRING, zip:INT>
)
ROW FORMAT DELIMITED
FIELDS TERMINATED BY '\001'
COLLECTION ITEMS TERMINATED BY '\002'
MAP KEYS TERMINATED BY '\003'
LINES TERMINATED BY '\n'
STORED AS TEXTFILE;
```

ROW FORMAT DELIMITED这组关键字必须要写在其他子句（除了STORED AS ... 子句）之前。

字符\001是^A的八进制数。ROW FORMAT DELIMITED FIELDS TERMINATED BY '\001'这个子句表明Hive将使用^A字符作为列分割符。

同样地，字符\002是^B的八进制数。ROW FORMAT DELIMITED COLLECTION ITEMS TERMINATED BY '\002'这个子句表明Hive将使用^B作为集合元素间的分隔符。

最后，字符\003是^C的八进制数。ROW FORMAT DELIMITED MAP KEYS TERMINATED BY '\003'这个子句表明Hive将使用^C作为map的键和值之间的分隔符。

子句LINES TERMINATED BY '...'和STORED AS ...不需要ROW FORMAT DELIMITED关键字。

事实上，Hive到目前为止对于LINES TERMINATED BY ...仅支持字符'\n'，也就是说行与行之间的分隔符只能为'\n'。因此这个子句现在使用起来还是有限制的。

用户可以重新指定列分割符及集合元素间分隔符，而map中键-值间分隔符仍然使用默认的文本文件格式，因此子句STORED AS TEXTFILE很少被使用到。本书中大多数情况下，我们使用的都是缺省情况下默认的TEXTFILE文件格式。

当然Hive还支持其他一些文件格式，但是我们将其推迟到第15章再进行论述。与其相关的一个话题是文件的压缩，这个我们将在第11章进

行讨论。

因此，虽然用户可以明确指定这些子句，但是在大多数情况下，大多数子句还是使用默认的分割符的，只需要明确指定那些需要替换的分隔符即可。



警告

这些规则只会影响到Hive在读取文件后将如何进行划分。只有在一些比较极端的情况下，才需要用户手工去将数据按正确的格式写入文件。

例如，如下表结构声明定义的是一个表数据按照逗号进行分割的表。

```
CREATE TABLE some_data (
  first FLOAT,
  second FLOAT,
  third FLOAT
)
ROW FORMAT DELIMITED
FIELDS TERMINATED BY ',';
```

用户还可以使用‘\t’（也就是制表键）作为字段分隔符。



提示

本例并没有合理地处理CSV格式（值是逗号分隔的）和TSV格式（值是制表键分隔的）文件通常使用的场景。CSV和TSV格式的文件中文件头中包含有列名，而列值字符串也有可能是包含在引号中的，而且其列值中也有可能包含有逗号或者制表键。第15章将介绍如果更优雅地处理这类文件。

这种强大的可定制功能使得可以很容易地使用Hive来处理那些由其他工具和各种各样的ETL（也就是数据抽取、数据转换和数据装载过程）程序产生的文件。

3.4 读时模式

当用户向传统数据库中写入数据的时候，不管是采用装载外部数据的方式，还是采用将一个查询的输出结果写入的方式，或者是使用UPDATE语句，等等，数据库对于存储都具有完全的控制力。数据库就是“守门人”。传统数据库是写时模式（schema on write），即数据在写入数据库时对模式进行检查。

Hive对底层存储并没有这样的控制。对于Hive要查询的数据，有很多种方式对其进行创建、修改，甚至损坏。因此，Hive不会在数据加载时进行验证，而是在查询时进行，也就是读时模式（schema on read）。

那么如果模式和文件内容并不匹配将会怎么样呢？Hive对此做的非常好，因为其可以读取这些数据。如果每行记录中的字段个数少于对应的模式中定义的字段个数的话，那么用户将会看到查询结果中有很多的null值。如果某些字段是数值型的，但是Hive在读取时发现存在非数值型的字符串值的话，那么对于那些字段将会返回null值。除此之外的其他情况下，Hive都极力尝试尽可能地将各种错误恢复过来。

第4章 HiveQL：数据定义

HiveQL是Hive查询语言。和普遍使用的所有SQL方言一样，它不完全遵守任一种ANSI SQL标准的修订版。HiveQL可能和MySQL的方言最接近，但是两者还是存在显著性差异的。Hive不支持行级插入操作、更新操作和删除操作。Hive也不支持事务。Hive增加了在Hadoop背景下的可以提供更高性能的扩展，以及一些个性化的扩展，甚至还增加了一些外部程序。

当然了，大部分的HiveQL还是很常见的。本章以及随后的几章将会使用一些典型的例子来讲解HiveQL的那些特性。在某些情况下，我们会从整体上简要地谈到一些细节，然后会在后面的章节里再去比较完整地进行讨论。

本章开始的部分是HiveQL所谓的数据定义语言部分，其用于创建、修改和删除数据库、表、视图、函数和索引。本章将会涉及到数据库和表，将会讨论视图有关内容，将讨论索引，会讲述到函数。

随着介绍的继续，我们也将讨论SHOW和DESCRIBE这些用于列举和描述信息的命令。

随后的几章将会研究HiveQL的数据操作语言部分，其用于将数据导入到Hive表中，以及将数据抽取到文件系统中。这些章节中还会介绍如何通过查询、分组、过滤、连接等操作研究和操作数据。

4.1 Hive中的数据库

Hive中数据库的概念本质上仅仅是表的一个目录或者命名空间。然而，对于具有很多组和用户的大集群来说，这是非常有用的，因为这样可以避免表命名冲突。通常会使用数据库来将生产表组织成逻辑组。

如果用户没有显式指定数据库，那么将会使用默认的数据库 default。

下面这个例子就展示了如何创建一个数据库:

```
hive> CREATE DATABASE financials;
```

如果数据库**financials**已经存在的话，那么将会抛出一个错误信息。使用如下语句可以避免在这种情况下抛出错误信息:

```
hive> CREATE DATABASE IF NOT EXISTS financials;
```

虽然通常情况下用户还是期望在同名数据库已经存在的情况下能够抛出警告信息的，但是**IF NOT EXISTS**这个子句对于那些在继续执行之前需要根据需要实时创建数据库的情况来说是非常有用的。

在所有的数据库相关的命令中，都可以使用**SCHEMA**这个关键字来替代关键字**TABLE**。

随时可以通过如下命令方式查看Hive中所包含的数据库:

```
hive> SHOW DATABASES;
default
financials

hive> CREATE DATABASE human_resources;

hive> SHOW DATABASES;
default
financials
human_resources
```

如果数据库非常多的话，那么可以使用正则表达式匹配来筛选出需要的数据库名，正则表达式这个概念，将会在第6.2.3节“”介绍。下面这个例子展示的是列举出所有以字母h开头，以其他字符结尾（即.*部分含义）的数据库名:

```
hive> SHOW DATABASES LIKE 'h.*';
human_resources
hive> ...
```

Hive会为每个数据库创建一个目录。数据库中的表将会以这个数据库目录的子目录形式存储。有一个例外就是**default**数据库中的表，因为这个数据库本身没有自己的目录。

数据库所在的目录位于属性hive.metastore.warehouse.dir所指定的顶层目录之后，这个配置项我们已经在前面的第2.5.1节“”和第2.5.2节“”中进行了介绍。假设用户使用的是这个配置项默认的配置，也就是/user/hive/warehouse，那么当我们创建数据库financials时，Hive将会对应地创建一个目录/user/hive/warehouse/financials.db。这里请注意，数据库的文件目录名是以.db结尾的。

用户可以通过如下的命令来修改这个默认的位置：

```
hive> CREATE DATABASE financials
> LOCATION '/my/preferred/directory';
```

用户也可以为这个数据库增加一个描述信息，这样通过DESCRIBE DATABASE <database> 命令就可以查看到该信息。

```
hive> CREATE DATABASE financials
> COMMENT 'Holds all financial tables';

hive> DESCRIBE DATABASE financials;
financials Holds all financial tables
hdfs://master-server/user/hive/warehouse/financials.db
```

从上面的例子中，我们可以注意到，DESCRIBE DATABASE语句也会显示出这个数据库所在的文件目录位置路径。在这个例子中，URI格式是hdfs。如果安装的是MapR，那么这里就应该是maprfs。对于亚马逊弹性MapReduce（EMR）集群，这里应该是hdfs，但是用户可以设置hive.metastore.warehouse.dir为亚马逊S3特定的格式（例如，属性值设置为s3n://bucketname...）。用户可以使用s3作为模式，但是如果使用新版的规则s3n会更好。

前面DESCRIBE DATABASE语句的输出中，我们使用了master-server来代表URI权限，也就是说应该是由文件系统的“主节点”（例如，HDFS中运行NameNode服务的那台服务器）的服务器名加上一个可选的端口号构成的（例如，服务器名：端口号这样的格式）。如果用户执行的是伪分布式模式，那么主节点服务器名称就应该是localhost。对于本地模式，这个路径应该是一个本地路径，例如file:///user/hive/warehouse/financials.db。

如果这部分信息省略了，那么Hive将会使用Hadoop配置文件中的配置项fs.default.name作为master-server所对应的服务器名和端口号，

这个配置文件可以在\$HADOOP_HOME/conf这个目录下找到。

需要明确的是，`hdfs://user/hive/warehouse/financials.db`和`hdfs://master-server/user/hive/warehouse/financials.db`是等价的，其中`master-server`是主节点的DNS名和可选的端口号。

为了保持完整性，当用户指定一个相对路径（例如，`some/relative/path`）时，对于HDFS和Hive，都会将这个相对路径放到分布式文件系统的指定根目录下（例如，`hdfs://user/<user-name>`）。然而，如果用户是在本地模式下执行的话，那么当前的本地工作目录将是`some/relative/path`的父目录。

为了脚本的可移植性，通常会省略掉那个服务器和端口号信息，而只有在涉及到另一个分布式文件系统实例（包括S3存储）的时候才会指明该信息。

此外，用户还可以为数据库增加一些和其相关的键-值对属性信息，尽管目前仅有的功能就是提供了一种可以通过`DESCRIBE DATABASE EXTENDED <database>`语句显示出这些信息的方式：

```
hive> CREATE DATABASE financials
>   WITH DBPROPERTIES ('creator' = 'Mark Moneybags', 'date' = '2012-01-02');

hive> DESCRIBE DATABASE financials;
financials  hdfs://master-server/user/hive/warehouse/financials.db

hive> DESCRIBE DATABASE EXTENDED financials;
financials  hdfs://master-server/user/hive/warehouse/financials.db
{date=2012-01-02, creator=Mark Moneybags};
```

`USE`命令用于将某个数据库设置为用户当前的工作数据库，和在文件系统中切换工作目录是一个概念：

```
hive> USE financials;
```

现在，使用像`SHOW TABLES`这样的命令就会显示当前这个数据库下所有的表。

不幸的是，并没有一个命令可以让用户查看当前所在的是哪个数据库！幸运的是，在Hive中是可以重复使用`USE...`命令的，这是因为Hive中并没有嵌套数据库的概念。

可以回想下，在”中提到过，可以通过设置一个属性值来在提示符里面显示当前所在的数据库（Hive v0.8.0版本以及之后的版本才支持此功能）：

```
hive> set hive.cli.print.current.db=true;  
hive (financials)> USE default;  
hive (default)> set hive.cli.print.current.db=false;  
hive> ...
```

最后，用户可以删除数据库：

```
hive> DROP DATABASE IF EXISTS financials;
```

IF EXISTS子句是可选的，如果加了这个子句，就可以避免因数据库financials不存在而抛出警告信息。

默认情况下，Hive是不允许用户删除一个包含有表的数据库的。用户要么先删除数据库中的表，然后再删除数据库；要么在删除命令的最后面加上关键字CASCADE，这样可以使Hive自行先删除数据库中的表：

```
hive> DROP DATABASE IF EXISTS financials CASCADE;
```

如果使用的是RESTRICT这个关键字而不是CASCADE这个关键字的话，那么就和默认情况一样，也就是，如果想删除数据库，那么必须先要删除掉该数据库中的所有表。

如果某个数据库被删除了，那么其对应的目录也同时会被删除。

4.2 修改数据库

用户可以使用ALTER DATABASE命令为某个数据库的DBPROPERTIES设置键-值对属性值，来描述这个数据库的属性信息。数据库的其他元数据信息都是不可更改的，包括数据库名和数据库所在的目录位置：

```
hive> ALTER DATABASE financials SET DBPROPERTIES ('edited-by' = 'Joe Dba');
```

没有办法可以删除或者“重置”数据库属性。

4.3 创建表

CREATE TABLE语句遵从SQL语法惯例，但是Hive的这个语句中具有显著的功能扩展，使其可以具有更广泛的灵活性。例如，可以定义表的数据文件存储在什么位置、使用什么样的存储格式，等等。前面我们在”中已经讨论了很多种存储格式，同时在稍后的我们将会再次探讨一下更加高级的格式。本节中，我们会讨论其他一些在CREATE TABLE语句中可以使用到的选项，下面这个表结构适用于前面我们在”中所声明的employees表：

```
CREATE TABLE IF NOT EXISTS mydb.employees (
  name          STRING COMMENT 'Employee name',
  salary        FLOAT COMMENT 'Employee salary',
  subordinates  ARRAY<STRING> COMMENT 'Names of subordinates',
  deductions    MAP<STRING, FLOAT>
                 COMMENT 'Keys are deductions names, values are percentages',
  address       STRUCT<street:STRING, city:STRING, state:STRING, zip:INT>
                 COMMENT 'Home address'
  COMMENT 'Description of the table'
TBLPROPERTIES ('creator'='me', 'created_at'='2012-01-02 10:00:00', ...)
LOCATION '/user/hive/warehouse/mydb.db/employees';
```

首先，我们可以注意到，如果用户当前所处的数据库并非是目标数据库，那么用户是可以在表名前增加一个数据库名来进行指定的，也就是例子中的mydb。

如果用户增加上可选项IF NOT EXISTS，那么若表已经存在了，Hive就会忽略掉后面的执行语句，而且不会有任何提示。在那些第一次执行时需要创建表的脚本中，这么写是非常有用的。

然而，这个语句还有一个用户需要注意的问题。如果用户所指定的表的模式和已经存在的这个表的模式不同的话，Hive不会为此做出提示。如果用户的意图是使这个表具有重新指定的那个新的模式的话，那么就需要先删除这个表，也就是丢弃之前的数据，然后再重建这张表。用户可以考虑使用一个或多个ALTER TABLE语句来修改已经存在的表的结构。有更详细的信息。



提示

如果用户使用了IF NOT EXISTS，而且这个已经存在的表和CREATE TABLE语句后指定的模式是不同的。Hive会忽略掉这个差异。

用户可以在字段类型后为每个字段增加一个注释。和数据库一样，用户也可以为这个表本身添加一个注释，还可以自定义一个或多个表属性。大多数情况下，TBLPROPERTIES的主要作用是按键-值对的格式为表增加额外的文档说明。但是，当我们检查Hive和像DynamoDB（请参考第17.5节“DynamoDB”中的内容）这样的数据库间的集成时，我们可以发现TBLPROPERTIES还可用作表示关于数据库连接的必要的元数据信息。

Hive会自动增加两个表属性：一个是last_modified_by，其保存着最后修改这个表的用户的用户名；另一个是last_modified_time，其保存着最后一次修改的新纪元时间秒。



提示

Hive v0.10.0版本中有一个功能增强计划，也就是增加一个SHOW TBLPROPERTIES table_name命令，用于列举出某个表的TBLPROPERTIES属性信息。

最后，可以看到我们可以根据情况为表中的数据指定一个存储路径（和元数据截然不同的是，元数据总是会保存这个路径）。在这个例子中，我们使用的Hive将会使用的默认的路径/user/hive/warehouse/mydb.db/employees。其中，/user/hive/warehouse是默认的“数据仓库”路径地址（这个之前有讨论过），mydb.db是数据库目录，employees是表目录。

默认情况下，Hive总是将创建的表的目录放置在这个表所属的数据库目录之后。不过，default数据库是个例外，其在/user/hive/warehouse下并没有对应一个数据库目录。因此default数据

库中的表目录会直接位于`/user/hive/warehouse`目录之后（除了用户明确指定为其他路径）。



提示

为了避免潜在产生混淆的可能性，如果用户不想使用默认的表路径，那么最好是使用外部表。查看获得更详细信息。

用户还可以拷贝一张已经存在的表的表模式（而无需拷贝数据）：

```
CREATE TABLE IF NOT EXISTS mydb.employees2
LIKE mydb.employees;
```

这个版本还可以接受可选的**LOCATION**语句，但是注意其他的属性，包括模式，都是不可能重新定义的，这些信息直接从原始表获得。

`SHOW TABLES`命令可以列举出所有的表。如果不增加其他参数，那么只会显示当前工作数据库下的表。假设我们已经创建了一些其他表，`table1`和`table2`，而且我们的工作数据库是`mydb`：

```
hive> USE mydb;
hive> SHOW TABLES;
employees
table1
table2
```

即使我们不在那个数据库下，我们还是可以列举指定数据库下的表的：

```
hive> USE default;
hive> SHOW TABLES IN mydb;
employees
table1
table2
```

如果我们有很多的表，那么我们可以使用正则表达式来过滤出所需要的表名。正则表达式这个概念我们将在进行讨论。

```
hive> USE mydb;  
hive> SHOW TABLES 'empl.*';  
employees
```

Hive并非支持所有的正则表达式功能。如果用户了解正则表达式的话，最好事先测试下备选的正则表达式是否真正奏效！

单引号中的正则表达式表示的是选择所有以empl开头并以其他任意字符（也就是.*部分）结尾的表名。



提示

IN database_name语句和对表名使用正则表达式两个功能尚不支持同时使用。

我们也可以使用DESCRIBE EXTENDED mydb.employees命令来查看这个表的详细表结构信息。（如果我们当前所处的工作数据库就是mydb的话，那么我们可以不加mydb.这个前缀。）下面显示的内容我们进行过格式调整，使之查看起来更加容易，而且我们还省略掉了一些无关紧要的细节，因为我们只关注我们感兴趣的信息：

```
hive> DESCRIBE EXTENDED mydb.employees;  
name      string      Employee name  
salary    float       Employee salary  
subordinates      array<string>  Names of subordinates  
deductions      map<string,float> Keys are deductions names, values are  
percentages  
address  struct<street:string,city:string,state:string,zip:int> Home address  
  
Detailed Table Information      Table(tableName:employees, dbName:mydb, owner:me,  
..  
location:hdfs://master-server/user/hive/warehouse/mydb.db/employees,  
parameters:{creator=me, created_at='2012-01-02 10:00:00',  
           last_modified_user=me, last_modified_time=1337544510,  
           comment:Description of the table, ...}, ...)
```

使用FORMATTED关键字替代EXTENDED关键字的话，可以提供更加可读的和冗长的输出信息。（译者注：实际情况是使用FORMATTED要更多些，因为其输出内容详细而且可读性强）

上面输出信息的第一段是和没有使用关键字EXTENDED或者FROMATTED时输出的结果一样的（例如，只输出包含有列描述信息的表结构信息）。

如果用户只想查看某一个列的信息，那么只要在表名后增加这个字段的名称即可。这种情况下，使用EXTENDED关键字也不会增加更多的输出信息：

```
hive> DESCRIBE mydb.employees.salary;
salary float Employee salary
```

回到之前的那个包含详细扩展信息的输出。我们需要特别注意以location:开头的那行描述信息。这个是Hive在HDFS中的存储表中数据的完整的URL目录路径，这个我们之前有讨论过的。



警告

我们说过last_modified_by 和last_modified_time两个表属性是会自动创建的。如果没有定义任何的用户自定义表属性的话，那么它们也不会显示在表的详细信息中！

4.3.1 管理表

我们目前所创建的表都是所谓的管理表，有时也被称为内部表。因为这种表，Hive会（或多或少地）控制着数据的生命周期。正如我们所看见的，Hive默认情况下会将这些表的数据存储在由配置项hive.metastore.warehouse.dir（例如，/user/hive/warehouse）所定义的目录的子目录下。

当我们删除一个管理表时（参考第4.5节“），Hive也会删除这个表中数据。

但是，管理表不方便和其他工作共享数据。例如，假设我们有一份由Pig或者其他工具创建并且主要由这一工具使用的数据，同时我们还想使用Hive在这份数据上执行一些查询，可是并没有给予Hive对数据的所有权，我们可以创建一个外部表指向这份数据，而并不需要对其实具有所有权。

4.3.2 外部表

假设我们正在分析来自股票市场的数据。我们会定期地从像 Infochimps(<http://infochimps.com/datasets>)这样的数据源接入关于 NASDAQ和NYSE的数据，然后使用很多工具来分析这份数据。（我们可以看到数据集名称分别为 infochimps_dataset_4777_download_16185 和 infochimps_dataset_4778_download_16677，实际上该数据来源于 Yahoo!财经。）我们后面将要使用的模式和这2份源数据都是匹配的。我们假设这些数据文件位于分布式文件系统的/data/stocks目录下。

下面的语句将创建一个外部表，其可以读取所有位于/data/stocks 目录下的以逗号分隔的数据：

```
CREATE EXTERNAL TABLE IF NOT EXISTS stocks (
  exchange      STRING,
  symbol        STRING,
  ymd           STRING,
  price_open    FLOAT,
  price_high    FLOAT,
  price_low     FLOAT,
  price_close   FLOAT,
  volume        INT,
  price_adj_close FLOAT)
ROW FORMAT DELIMITED FIELDS TERMINATED BY ','
LOCATION '/data/stocks';
```

关键字EXTENAL告诉Hive这个表是外部的，而后面的 LOCATION...子句则用于告诉Hive数据位于哪个路径下。

因为表是外部的，所以Hive并非认为其完全拥有这份数据。因此，删除该表并不会删除掉这份数据，不过描述表的元数据信息会被删除掉。

管理表和外部表有一些小小的区别，那就是，有些HiveQL语法结构并不适用于外部表。后面当我们遇到这些问题的时候，我们再来进行讲述。

然而，我们需要清楚的重要的一点是管理表和外部表之间的差异要比刚开始所看到的小得多。即使对于管理表，用户也是可以知道数据是位于哪个路径下的，因此用户也是可以使用其他工具（例如 hadoop的dfs命令等）来修改甚至删除管理表所在的路径目录下的数据

的。可能从严格意义上来说，Hive是管理着这些目录和文件，但是其并非具有对它们的完全控制权限！回想下，在第3.4节“读时模式”中，我们说过，Hive实际上对于所存储的文件的完整性以及数据内容是否和表模式相一致并没有支配能力，甚至管理表都没有给用户提供这些管理能力。

尽管如此，好的软件设计的一般原则是表达意图。如果数据会被多个工具共享，那么可以创建一个外部表，来明确对数据的所有权。

用户可以在DESCRIBE EXTENDED tablename语句的输出中查看到表是否是管理表或外部表。在末尾的详细表信息输出中，对于管理表，用户可以看到如下信息：

```
... tableType:MANAGED_TABLE)
```

对于外部表，用户可以查看到如下信息：

```
... tableType:EXTERNAL_TABLE)
```

对于管理表，用户还可以对一张存在的表进行表结构复制（而不会复制数据）：

```
CREATE EXTERNAL TABLE IF NOT EXISTS mydb.employees3
LIKE mydb.employees
LOCATION '/path/to/data';
```



提示

这里，如果语句中省略掉EXTERNAL关键字而且源表是外部表的话，那么生成的新表也将是外部表。如果语句中省略掉EXTERNAL关键字而且源表是管理表的话，那么生成的新表也将是管理表。但是，如果语句中包含有EXTERNAL关键字而且源表是管理表的话，那么生成的新表将是外部表。即使在这种场景下，LOCATION子句同样是可选的。

4.4 分区表、管理表

数据分区的一般概念存在已久。其可以有多种形式，但是通常使用分区来水平分散压力，将数据从物理上转移到和使用最频繁的用户更近的地方，以及实现其他目的。

Hive中有分区表的概念。我们可以看到分区表具有重要的性能优势，而且分区表还可以将数据以一种符合逻辑的方式进行组织，比如分层存储。

我们首先会讨论下分区管理表。重新来看之前的那张employees表并假设我们在一个非常大的跨国公司工作。我们的HR人员经常会执行一些带WHERE语句的查询，这样可以将结果限制在某个特定的国家或者某个特定的第一级细分（例如‘美国的州’或者加拿大的省）。

（第一级细分是一个存在的术语，例如：

http://www.commodatahub.com/state_source.jsp这里就有使用到。）为简单起见我们将只使用到state（州）。在address（住址）字段中已经重复包含了州信息。这和state分区是不同的。我们可以在字段address中删除state元素。查询中并不会造成模糊不清的问题，因为我们需要通过使用address.state才能调用到address中这个元素的值。那么，让我们先按照country（国家）再按照state（州）来对数据进行分区吧：

```
CREATE TABLE employees (
  name          STRING,
  salary        FLOAT,
  subordinates  ARRAY<STRING>,
  deductions    MAP<STRING, FLOAT>,
  address       STRUCT<street:STRING, city:STRING, state:STRING, zip:INT>
)
PARTITIONED BY (country STRING, state STRING);
```

分区表改变了Hive对数据存储的组织方式。如果我们是在mydb数据库中创建的这个表，那么对于这个表只会有一个employees目录与之对应：

```
hdfs://master_server/user/hive/warehouse/mydb.db/employees
```

但是，Hive现在将会创建好可以反映分区结构的子目录。例如：

```
...
.../employees/country=CA/state=AB
.../employees/country=CA/state=BC
...
.../employees/country=US/state=AL
```

```
.../employees/country=US/state=AK  
...
```

是的，那些是实际的目录名称。州目录下将会包含有零个文件或者多个文件，这些文件中存放着那些州的雇员信息。

分区字段（这个例子中就是country和state）一旦创建好，表现得就和普通的字段一样。这里有一个已知的异常情况，是由一个bug引起的（参考第6.1.4节中的“聚合函数”内容）。事实上，除非需要优化查询性能，否则使用这些表的用户不需要关心这些“字段”是否是分区字段。

例如，下面这个查询语句将会查找出在美国伊利诺斯州的所有雇员：

```
SELECT * FROM employees  
WHERE country = 'US' AND state = 'IL';
```

需要注意的是，因为country和state的值已经包含在文件目录名称中了，所以也就没有必要将这些值存放到它们目录下的文件中了。事实上，数据只能从这些文件中获得，因此用户需要在表的模式中说明这点，而且这个数据浪费空间。

对数据进行分区，也许最重要的原因就是为了更快地查询。在前面那个将结果范围限制在伊利诺斯州的雇员的查询中，仅仅需要扫描一个目录下的内容即可。即使我们有成千上万个国家和州目录，除了一个目录其他的都可以忽略不计。对于非常大的数据集，分区可以显著地提高查询性能，除非对分区进行常见的范围筛选（例如，按照地理位置范围或按照时间范围等）。

当我们在WHERE子句中增加谓词来按照分区值进行过滤时，这些谓词被称为分区过滤器。

即使你做一个跨越整个美国的查询，Hive也只会读取65个文件目录，其中包含有50个州，9大地区，以及哥伦比亚特区和6个军事属地。可以通过如下链接查看完整的列表：

<http://www.50states.com/abbreviations.htm>。

当然，如果用户需要做一个查询，查询对象是全球各地的所有员工，那么这也是可以做到的。Hive会不得不读取每个文件目录，但这种宽范围的磁盘扫描还是比较少见的。

但是，如果表中的数据以及分区个数都非常大的话，执行这样一个包含所有分区的查询可能会触发一个巨大的MapReduce任务。一个高度建议的安全措施就是将Hive设置为“strict(严格)”模式，这样如果对分区表进行查询而WHERE子句没有加分区过滤的话，将会禁止提交这个任务。用户也可以按照下面的语句将属性值设置为“nonstrict(非严格)”：

```
hive> set hive.mapred.mode=strict;
hive> SELECT e.name, e.salary FROM employees e LIMIT 100;
FAILED: Error in semantic analysis: No partition predicate found for
Alias "e" Table "employees"

hive> set hive.mapred.mode=nonstrict;
hive> SELECT e.name, e.salary FROM employees e LIMIT 100;
John Doe 100000.0
...
```

可以通过SHOW PARTITIONS命令查看表中存在的所有分区：

```
hive> SHOW PARTITIONS employees;
...
Country=CA/state=AB
country=CA/state=BC
...
country=US/state=AL
country=US/state=AK
...
```

如果表中现在存在很多的分区，而用户只想查看是否存储某个特定分区键的分区的话，用户还可以在这个命令上增加一个指定了一个或者多个特定分区字段值的PARTITION子句，进行过滤查询：

```
hive> SHOW PARTITIONS employees PARTITION(country='US');
country=US/state=AL
country=US/state=AK
...
hive> SHOW PARTITIONS employees PARTITION(country='US', state='AK');
country=US/state=AK
```

DESCRIBE EXTENDED employees命令也会显示出分区键：

```
hive> DESCRIBE EXTENDED employees;
name          string,
salary        float,
...
address      struct<...>,
country      string,
state        string

Detailed Table Information...
partitionKeys:[FieldSchema(name:country, type:string, comment:null),
FieldSchema(name:state, type:string, comment:null)],
...
```

输出信息中的模式信息部分会将country和state以及其他字段列在一起，因为就查询而言，它们就是字段。Detailed Table Information（详细表信息）将country和state作为分区键处理。这两个键当前的注释都是null，我们也可以像给普通的字段增加注释一样给分区字段增加注释。

在管理表中用户可以通过载入数据的方式创建分区。如下例中的语句在从一个本地目录（\$HOME/california-employees）载入数据到表中的时候，将会创建一个US和CA（表示加利福尼亚州）分区。用户需要为每个分区字段指定一个值。请注意我们在HiveQL中是如何引用HOME环境变量的：

```
LOAD DATA LOCAL INPATH '${env:HOME}/california-employees'
INTO TABLE employees
PARTITION (country = 'US', state = 'CA');
```

Hive将会创建这个分区对应的目录.../employees/country=US/state=CA，而且\$HOME/california-employees这个目录下的文件将会被拷贝到上述分区目录下。参见第5.1节”中的内容。

4.4.1 外部分区表

外部表同样可以使用分区。事实上，用户可能会发现，这是管理大型生产数据集最常见的情况。这种结合给用户提供了可以和其他工具共享数据的方式，同时也优化了查询性能。

因为用户可以自己定义目录结构，因此用户对于目录结构的使用具有更多的灵活性。稍后我们将看到一个特别有用的例子。

我们举一个新例子，非常适合这种场景，即日志文件分析。对于日志信息，大多数的组织使用一个标准的格式，其中记录有时间戳、严重程度（例如ERROR、WARNING、INFO），也许还包含有服务器名称和进程ID，然后跟着一个可以为任何内容的文本信息。假设我们是在我们的环境中进行数据抽取、数据转换和数据装载过程（ETL），以及日志文件聚合过程的，将每条日志信息转换为按照制表键分割的记录，并将时间戳解析成年、月和日3个字段，剩余的hms部分（也就是时间戳剩余的小时、分钟和秒部分）作为一个字段，因为这样显得清楚多了。一种方式是用户可以使用Hive或者Pig内置的字符串解析函数来完成这个日志信息解析过程。另一种方式是，我们可以使用较小的数值类型来保存时间戳相关的字段以节省空间。这里，我们没有采用后面的解决办法。

我们可以按照如下方式来定义对应的Hive表：

```
CREATE EXTERNAL TABLE IF NOT EXISTS log_messages (
  hms      INT,
  severity STRING,
  server   STRING,
  process_id INT,
  message   STRING)
PARTITIONED BY (year INT, month INT, day INT)
ROW FORMAT DELIMITED FIELDS TERMINATED BY '\t';
```

我们现在假定将日志数据按照天进行划分，划分数据尺寸合适，而且按天这个粒度进行查询速度也足够快。

回想下，之前我们创建过一个非分区外部表，是一个股票交易表，那时要求使用一个LOCATION子句。对于外部分区表则没有这样的要求。有一个ALTER TABLE语句可以单独进行增加分区。这个语句需要为每一个分区键指定一个值，本例中，也就是需要为year、month和day这3个分区键都指定值（关于这个功能请参考4.6节中的内容）。下面是一个例子，演示如何增加一个2012年1月2日的分区：

```
ALTER TABLE log_messages ADD PARTITION(year = 2012, month = 1, day = 2)
LOCATION 'hdfs://master_server/data/log_messages/2012/01/02';
```

我们使用的目录组织习惯完全由我们自己定义。这里，我们按照分层目录结构组织，因为这是一个合乎逻辑的数据组织方式，但是并非要求一定如此。我们可以遵从Hive的目录命名习惯（例

如，`.../exchange=NASDAQ/symbol=AAPL`），但是也并非要求一定如此。

这种灵活性的一个有趣的优点是我们可以使用像Amazon S3这样的廉价的存储设备存储旧的数据，同时保存较新的更加“有趣的”数据到HDFS中。例如，每天我们可以使用如下的处理过程将一个月前的旧数据转移到S3中。

① 将分区下的数据拷贝到S3中。例如，用户可以使用hadoop distcp命令：

```
hadoop distcp /data/log_message/2011/12/02 s3n://ourbucket/logs/2011/12/02
```

② 修改表，将分区路径指向到S3路径：

```
ALTER TABLE log_messages PARTITION(year = 2011, month = 12, day = 2)
SET LOCATION 's3n://ourbucket/logs/2011/01/02';
```

③ 使用hadoop fs -rmr 命令删除掉HDFS中的这个分区数据：

```
hadoop fs -rmr /data/log_messages/2011/01/02
```

并非一定要是Amazon弹性MapReduce用户才能够这样使用S3。Apache Hadoop分支版本包含了对S3的支持。用户仍旧是可以查询这些数据的，甚至允许查询越过一个月时间范围的“界限”，也就是有些数据是从HDFS中读取的，有些数据是从S3中读取的！

顺便说一下，Hive不关心一个分区对应的分区目录是否存在或者分区目录下是否有文件。如果分区目录不存在或分区目录下没有文件，则对于这个过滤分区的查询将没有返回结果。当用户想在另外一个进程开始往分区中写数据之前创建好分区时，这样做是很方便的。数据一旦存在，对于这份数据的查询就会有返回结果。

这个功能所具有的另一个好处是：可以将新数据写入到一个专用的目录中，并与位于其他目录中的数据存在明显的区别。同时，不管用户是将旧数据转移到一个“存档”位置还是直接删除掉，新数据被篡改的风险都被降低了，因为新数据的数据子集位于不同的目录下。

和非分区外部表一样，Hive并不控制这些数据。即使表被删除，数据也不会被删除。

和分区管理表一样，通过SHOW PARTITIONS命令可以查看一个外部表的分区：

```
hive> SHOW PARTITIONS log_messages;
...
year=2011/month=12/day=31
year=2012/month=1/day=1
year=2012/month=1/day=2
...
```

同样地，DESCRIBE EXTENDED log_messages语句会将分区键作为表的模式的一部分，和partitionKeys列表的内容同时进行显示：

```
hive> DESCRIBE EXTENDED log_messages;
...
message      string,
year         int,
month        int,
day          int

Detailed Table Information...
partitionKeys:[FieldSchema(name:year, type:int, comment:null),
FieldSchema(name:month, type:int, comment:null),
FieldSchema(name:day, type:int, comment:null)],
...
```

这个输出缺少了一个非常重要的信息，那就是分区数据实际存在的路径。这里有一个路径字段，但是该字段仅仅表示如果表是管理表其会使用到的Hive默认的目录。不过，我们可以通过如下方式查看到分区数据所在的路径：

```
hive> DESCRIBE EXTENDED log_messages PARTITION (year=2012, month=1, day=2);
...
location:s3n://ourbucket/logs/2011/01/02,
...
```

我们通常会使用分区外部表，因为它具有非常多的优点，例如逻辑数据管理、高性能的查询等。

ALTER TABLE ... ADD PARTITION语句并非只有对外部表才能够使用。对于管理表，当有分区数据不是由我们之前讨论过的LOAD和INSERT语句产生时，用户同样可以使用这个命令指定分区路径。用

户需要记住并非所有的表数据都是放在通常的Hive“warehouse”目录下的，同时当删除管理表时，这些数据不会连带被删除掉！因此，从“理智的”角度来看，是否敢于对管理表使用这个功能是一个问题。

4.4.2 自定义表的存储格式

在第3.3节“文本文件数据编码”中，我们谈论过Hive的默认存储格式是文本文件格式，这个也可以通过可选的子句STORED AS TEXTFILE显式指定，同时用户还可以在创建表时指定各种各样的分隔符。这里我们重新展示下之前讨论过的那个employees表：

```
CREATE TABLE employees (
  name          STRING,
  salary        FLOAT,
  subordinates ARRAY<STRING>,
  deductions   MAP<STRING, FLOAT>,
  address       STRUCT<street:STRING, city:STRING, state:STRING, zip:INT>
)
ROW FORMAT DELIMITED
FIELDS TERMINATED BY '\001'
COLLECTION ITEMS TERMINATED BY '\002'
MAP KEYS TERMINATED BY '\003'
LINES TERMINATED BY '\n'
STORED AS TEXTFILE;
```

TEXTFILE意味着所有字段都使用字母、数字、字符编码，包括那些国际字符集，尽管我们可以发现Hive默认是使用不可见字符来作为“终结者”（分隔符）的。使用TEXTFILE就意味着，每一行被认为是一个单独的记录。

用户可以将TEXTFILE替换为其他Hive所支持的内置文件格式，包括SEQUENCEFILE和RCFILE，这两种文件格式都是使用二进制编码和压缩（可选）来优化磁盘空间使用以及I/O带宽性能的。这些文件格式在和将会有更详细的介绍。

对于记录是如何被编码成文件的，以及列是如何被编码为记录的，Hive指出了它们之间的不同。用户可以分别自定义这些行为。

记录编码是通过一个inputformat对象来控制的（例如TEXTFILE后面的Java代码实现）。Hive使用了一个名为org.apache.hadoop.mapred.TextInputFormat的Java类（编译后的模块）。如果用户不熟悉Java的话，这种点分割的命名语法表明了包的

一个分层的树形命名空间，这个结构和Java代码的目录结构是对应的。最后一个名字，`TextInputFormat`，是位于最顶层包`mapred`下的一个类。

记录的解析是由序列化器/反序列化器（或者缩写为`SerDe`）来控制的。对于`TEXTFILE`和我们在第3章讨论的编码以及上面我们所重申的例子，Hive所使用的`SerDe`是另外一个被称为`org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe`的Java类。

为了保持完整性，Hive还使用一个叫做`outputformat`的对象来将查询的输出写入到文件中或者输出到控制台。对于`TEXTFILE`，用于输出的Java类名为`org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat`。



提示

Hive使用一个`inputformat`对象将输入流分割成记录，然后使用一个`outputformat`对象来将记录格式化为输出流（例如查询的输出结果），再使用一个`SerDe`在读数据时将记录解析成列，在写数据时将列编码成记录。在第15章我们将对此展开更深入的讨论。

用户还可以指定第三方的输入和输出格式以及`SerDe`，这个功能允许用户自定义Hive本身不支持的其他广泛的文件格式。

这里有一个使用了自定义`SerDe`、输入格式和输出格式的完整的例子，其可以通过Avro协议访问这些文件，第5.11节“AvroHive `SerDe`”中将会介绍到Avro协议：

```
CREATE TABLE kst
PARTITIONED BY (ds string)
ROW FORMAT SERDE 'com.linkedin.haivvreo.AvroSerDe'
WITH SERDEPROPERTIES ('schema.url'='http://schema_provider/kst.avsc')
STORED AS
INPUTFORMAT 'com.linkedin.haivvreo.AvroContainerInputFormat'
OUTPUTFORMAT 'com.linkedin.haivvreo.AvroContainerOutputFormat';
```

`ROW FORMAT SERDE ...`指定了使用的`SerDe`。Hive提供了`WITH SERDEPROPERTIES`功能，允许用户传递配置信息给`SerDe`。Hive本身

并不知晓这些属性的含义，需要SerDe去决定这些属性所代表的含义。需要注意的是，每个属性名称和值都应该是带引号的字符串。

STORED AS INPUTFORMAT ... OUTPUTFORMAT ...子句分别指定了用于输入格式和输出格式的Java类。如果要指定，用户必须对输入格式和输出格式都进行指定。

需要注意的是，DESCRIBE EXTENDED table命令会在DETAILED TABLE INFORMATION部分列举出输入和输出格式以及SerDe和SerDe所自带的属性信息。对于我们的例子，我们可以查看到如下信息：

```
hive> DESCRIBE EXTENDED kst
...
inputFormat:com.linkedin.haivvreo.AvroContainerInputFormat,
outputFormat:com.linkedin.haivvreo.AvroContainerOutputFormat,
...
serdeInfo:SerDeInfo(name:null,
serializationLib:com.linkedin.haivvreo.AvroSerDe,
parameters:{schema.url=http://schema_provider/kst.avsc})
...
```

最后，还有一些额外的CREATE TABLE子句来更详细地描述数据期望是按照什么样子存储的。我们重新扩展下在第4.3.2节“外部表”中使用到的stocks表：

```
CREATE EXTERNAL TABLE IF NOT EXISTS stocks (
  exchange      STRING,
  symbol        STRING,
  ymd           STRING,
  price_open    FLOAT,
  price_high    FLOAT,
  price_low     FLOAT,
  price_close   FLOAT,
  volume        INT,
  price_adj_close FLOAT)
CLUSTERED BY (exchange, symbol)
SORTED BY (ymd ASC)
INTO 96 BUCKETS
ROW FORMAT DELIMITED FIELDS TERMINATED BY ','
LOCATION '/data/stocks';
```

CLUSTERED BY ... INTO ... BUCKETS子句还可以后接一个可选的SORTED BY ...子句，用来优化某些特定类型的查询，在第9.6节“分桶表数据存储”中将会更详细地进行讨论。

4.5 删除表

Hive支持和SQL中DROP TABLE 命令类似的操作:

```
DROP TABLE IF EXISTS employees;
```

可以选择是否使用IF EXITST关键字。如果没有使用这个关键字而且表并不存在的话，那么将会抛出一个错误信息。

对于管理表，表的元数据信息和表内的数据都会被删除。



提示

事实上，如果用户开启了Hadoop回收站功能（这个功能默认是关闭的），那么数据将会被转移到用户在分布式文件系统中的用户根目录下的.Trash目录下，也就是HDFS中的`/user/$USER/.Trash`目录。如果想开启这个功能，只需要将配置属性`fs.trash.interval`的值设置为一个合理的正整数即可。这个值是“回收站检查点”间的时间间隔，单位是分钟。因此如果设置值为1440，那么就表示是24小时。不过并不能保证所有的分布式系统以及所有版本都是支持的这个功能的。如果用户不小心删除了一张存储着重要数据的管理表的话，那么可以先重建表，然后重建所需要的分区，再从.Trash目录中将误删的文件移动到正确的文件目录下（使用文件系统命令）来重新存储数据。

对于外部表，表的元数据信息会被删除，但是表中的数据不会被删除。

4.6 修改表

大多数的表属性可以通过ALTER TABLE语句来进行修改。这种操作会修改元数据，但不会修改数据本身。这些语句可用于修改表模式中出现的错误、改变分区路径（在第4.4.1节“外部分区表”中有讨论过），以及其他一些操作。



警告

ALTER TABLE仅仅会修改表元数据，表数据本身不会有任何修改。需要用户自己确认所有的修改都和真实的数据是一致的。

4.6.1 表重命名

使用以下这个语句可以将表log_messages重命名为logmsgs:

```
ALTER TABLE log_messages RENAME TO logmsgs;
```

4.6.2 增加、修改和删除表分区

正如我们前面所见到的，ALTER TABLE table ADD PARTITION ...语句用于为表（通常是外部表）增加一个新的分区。这里我们增加可提供的可选项，然后多次重复前面的分区路径语句：

```
ALTER TABLE log_messages ADD IF NOT EXISTS
PARTITION (year = 2011, month = 1, day = 1) LOCATION '/logs/2011/01/01'
PARTITION (year = 2011, month = 1, day = 2) LOCATION '/logs/2011/01/02'
PARTITION (year = 2011, month = 1, day = 3) LOCATION '/logs/2011/01/03'
...;
```

当使用Hive v0.8.0或其后的版本时，在同一个查询中可以同时增加多个分区。一如既往，IF NOT EXISTS也是可选的，而且含义不变。



警告

Hive v0.7.*版本允许用户指定多个分区，但是实际上只会使用第一个指定的分区，而将其他的分区默认省略掉了！其替代方案是，对每一个分区都使用ALTER STATEMENT语句。

同时，用户还可以通过高效地移动位置来修改某个分区的路径：

```
ALTER TABLE log_messages PARTITION(year = 2011, month = 12, day = 2)
SET LOCATION 's3n://ourbucket/logs/2011/01/02';
```

这个命令不会将数据从旧的路径转移走，也不会删除旧的数据。

最后，用户可以通过如下语句删除某个分区：

```
ALTER TABLE log_messages DROP IF EXISTS PARTITION(year = 2011, month = 12, day = 2);
```

按照常规，上面语句中的IF EXISTS 子句是可选的。对于管理表，即使是使用ALTER TABLE ... ADD PARTITION 语句增加的分区，分区内的数据也是会同时和元数据信息一起被删除的。对于外部表，分区内数据不会被删除。

还有其他一些和分区相关的ALTER语句将会在 第4.6.7”和第4.6.8节“中进行讨论。

4.6.3 修改列信息

用户可以对某个字段进行重命名，并修改其位置、类型或者注释：

```
ALTER TABLE log_messages
CHANGE COLUMN hms hours_minutes_seconds INT
COMMENT 'The hours, minutes, and seconds part of the timestamp'
AFTER severity;
```

即使字段名或者字段类型没有改变，用户也需要完全指定旧的字段名，并给出新的字段名及新的字段类型。关键字COLUMN 和 COMMENT子句都是可选的。前面所演示的例子中，我们将字段转移到severity字段之后。如果用户想将这个字段移动到第一个位置，那么只需要使用FIRST关键字替代 AFTER other_column子句即可。

和通常一样，这个命令只会修改元数据信息。如果用户移动的是字段，那么数据也应当和新的模式匹配或者通过其他某些方法修改数据以使其能够和模式匹配。

4.6.4 增加列

用户可以在分区字段之前增加新的字段到已有的字段之后。

```
ALTER TABLE log_messages ADD COLUMNS (
  app_name STRING COMMENT 'Application name',
  session_id LONG COMMENT 'The current session id');
```

COMMENT子句和通常一样，是可选的。如果新增的字段中有某个或多个字段位置是错误的，那么需要使用 ALTER COULME 表名 CHANGE COLUMN语句逐一将字段调整到正确的位置。

4.6.5 删除或者替换列

下面这个例子移除了之前所有的字段并重新指定了新的字段：

```
ALTER TABLE log_messages REPLACE COLUMNS (
  hours_mins_secs INT COMMENT 'hour, minute, seconds from timestamp',
  severity STRING COMMENT 'The message severity'
  message STRING COMMENT 'The rest of the message');
```

这个语句实际上重命名了之前的hms字段并且从之前的表定义的模式中移除了字段server和process_id。因为是ALTER语句，所以只有表的元数据信息改变了。

REPLACE语句只能用于使用了如下2种内置SerDe模块的表：DynamicSerDe 或者 MetadataTypedColumnsetSerDe。回想一下，SerDe决定了记录是如何分解成字段的（反序列化过程）以及字段是如何写入到存储中的（序列化过程）。第15章有关于SerDe更详细的信息。

4.6.6 修改表属性

用户可以增加附加的表属性或者修改已经存在的属性，但是无法删除属性：

```
ALTER TABLE log_messages SET TBLPROPERTIES (
  'notes' = 'The process id is no longer captured; this column is always NULL');
```

4.6.7 修改存储属性

有几个ALTER TABLE 语句用于修改存储格式和SerDe属性。

下面这个语句将一个分区的存储格式修改成了SEQUENCE FILE，我们在第4.3节“创建表”中讨论过存储格式（第11.5节“sequence

file存储格式”和第15章有更详细的信息)：

```
ALTER TABLE log_messages
PARTITION(year = 2012, month = 1, day = 1)
SET FILEFORMAT SEQUENCEFILE;
```

如果表是分区表，那么需要使用PARTITION子句。

用户可以指定一个新的SerDe，并为其指定SerDe属性，或者修改已经存在的SerDe的属性。下面这个例子演示的表使用了一个名为com.example.JSONSerDe的Java类来处理记录使用JSON编码的文件：

```
ALTER TABLE table_using_JSON_storage
SET SERDE 'com.example.JSONSerDe'
WITH SERDEPROPERTIES (
  'prop1' = 'value1',
  'prop2' = 'value2');
```

SERDEPROPERTIES中的属性会被传递给SerDe模块（本例中，也就是com.example.JSONSerDe这个Java类）。需要注意的是，属性名（例如prop1）和属性值（例如value1）都应当是带引号的字符串。

SERDEPROPERTIES这个功能是一种方便的机制，它使得SerDe的各种实现都允许用户进行自定义。第15.10节“JSON SerDe”中我们将可以看到一个真实的JSON SerDe例子，以及它是如何使用SERDEPROPERTIES。

下面这个例子演示了如何向一个已经存在着的SerDe增加新的SERDEPROPERTIES属性：

```
ALTER TABLE table_using_JSON_storage
SET SERDEPROPERTIES (
  'prop3' = 'value3',
  'prop4' = 'value4');
```

我们可以修改在第4.3节“创建表”中讲到的存储属性：

```
ALTER TABLE stocks
CLUSTERED BY (exchange, symbol)
SORTED BY (symbol)
INTO 48 BUCKETS;
```

SORTED BY子句是可选的，但是CLUSTER BY和INTO ... BUCKETS 子句是必选的。（在 第9.6节“分桶表数据存储”中将会更详细介绍数据分桶。）

4.6.8 众多的修改表语句

在第12.3.2节“执行钩子”中，我们将讨论一种为各种操作增加执行“钩子”的技巧。ALTER TABLE ... TOUCH语句用于触发这些钩子：

```
ALTER TABLE log_messages TOUCH
PARTITION(year = 2012, month = 1, day = 1);
```

PARTITION 子句用于分区表。这种语句的一个典型应用场景是，当表中存储的文件在Hive之外被修改了，就会触发钩子的执行。例如，某个脚本往分区2012/01/01中写入了新的日志信息文件，可以在Hive CLI中进行下面的调用：

```
hive -e 'ALTER TABLE log_messages TOUCH PARTITION(year = 2012, month = 1, day = 1);'
```

如果表或者分区并不存在，那么这个语句也不会创建表或者分区。在这种情况下要使用合适的创建策略。

ALTER TABLE ... ARCHIVE PARTITION语句会将这个分区内的文件打成一个Hadoop压缩包（HAR）文件。但是这样仅仅可以降低文件系统中的文件数以及减轻*NameNode*的压力，而不会减少任何的存储空间（例如，通过压缩）：

```
ALTER TABLE log_messages ARCHIVE
PARTITION(year = 2012, month = 1, day = 1);
```

使用UNARCHIVE替换ARCHIVE就可以反向操作。这个功能只能用于分区表中独立的分区。

最后，Hive提供了各种保护。下面的语句可以分别防止分区被删除和被查询：

```
ALTER TABLE log_messages
PARTITION(year = 2012, month = 1, day = 1) ENABLE NO_DROP;
```

```
ALTER TABLE log_messages
PARTITION(year = 2012, month = 1, day = 1) ENABLE OFFLINE;
```

使用ENABLE替换DISABLE可以达到反向操作的目的。这些操作也都不可用于非分区表。

第5章 HiveQL：数据操作

本章将继续讨论HiveQL，也就是Hive查询语言，并关注于向表中装载数据和从表中抽取数据到文件系统的数据操作语言部分。

本章中，当我们讨论通过查询语言生成目标表时，大量使用到了SELECT ... WHERE语句。那么，我们为什么不先讲述SELECT ... WHERE语句，而直到下一章也就是才会阐述呢？

既然我们刚讨论了如何创建表，我们就会期望先解决随之而来的下一个问题，即如何装载数据到这些表中，然后我们才能有些东西供查询吧！我们假定用户已经理解了SQL的基础知识，因此这些语句对用户来说应该不陌生。如果用户对此并不熟悉，那么请到获取相关更详细的介绍。

5.1 向管理表中装载数据

既然Hive没有行级别的数据插入、数据更新和删除操作，那么往表中装载数据的唯一途径就是使用一种“大量”的数据装载操作。或者通过其他方式仅仅将文件写入到正确的目录下。

在第4.4节“分区表、管理表”中我们已经看到了一个如何装载数据到管理表中的例子，这里我们稍微对其增加些内容重新进行展示。我们新增了一个关键字OVERWRITE：

```
LOAD DATA LOCAL INPATH '${env:HOME}/california-employees'  
OVERWRITE INTO TABLE employees  
PARTITION (country = 'US', state = 'CA');
```

如果分区目录不存在的话，这个命令会先创建分区目录，然后再将数据拷贝到该目录下。

如果目标表是非分区表，那么语句中应该省略PARTITION子句。

通常情况下指定的路径应该是一个目录，而不是单个独立的文件。Hive会将所有文件都拷贝到这个目录中。这使得用户将更方便地

组织数据到多文件中，同时，在不修改Hive脚本的前提下修改文件命名规则。不管怎么样，文件都会被拷贝到目标表路径下而且文件名会保持不变。

如果使用了**LOCAL**这个关键字，那么这个路径应该为本地文件系统路径。数据将会被拷贝到目标位置。如果省略掉**LOCAL**关键字，那么这个路径应该是分布式文件系统中的路径。这种情况下，数据是从这个路径转移到目标位置的。



提示

LOAD DATA LOCAL...拷贝本地数据到位于分布式文件系统上的目标位置，而**LOAD DATA ...**(也就是没有使用**LOCAL**)转移数据到目标位置。

之所以会存在这种差异，是因为用户在分布式文件系统中可能并不需要重复的多份数据文件拷贝。

同时，因为文件是以这种方式移动的，Hive要求源文件和目标文件以及目录应该在同一个文件系统中。例如，用户不可以使用**LOAD DATA**语句将数据从一个集群的**HDFS**中转载（转移）到另一个集群的**HDFS**中。

指定全路径会具有更好的鲁棒性，但也同样支持相对路径。当使用本地模式执行时，相对路径相对的是当Hive CLI启动时用户的工作目录。对于分布式或者伪分布式模式，这个路径解读为相对于分布式文件系统中用户的根目录，该目录在**HDFS**和**MapRFS**中默认为/**user/\$USER**。

如果用户指定了**OVERWRITE**关键字，那么目标文件夹中之前存在的数据将会被先删除掉。如果没有这个关键字，仅仅会把新增的文件增加到目标文件夹中而不会删除之前的数据。然而，如果目标文件夹中已经存在和装载的文件同名的文件，那么旧的同名文件将会被覆盖重写。
（译者注：事实上如果没有使用OVERWRITE关键字，而目标文件夹下已经存在同名的文件时，会保留之前的文件并且会重命名新文件为“之前的文件名_序列号”）



提示

Hive v0.9.0版本之前的版本中存在如下bug:如果没有使用OVERWRITE关键字，目标文件夹中已经存在和转载文件同名的文件的话，之前的文件会被覆盖重写。因此会产生数据丢失。这个bug在v0.9.0版本中已经修复了。

如果目标表是分区表那么需要使用PARTITION子句，而且用户还必须为每个分区的键指定一个值。

按照之前所说的那个例子，数据现在将会存放到如下这个文件夹中：

```
hdfs://master_server/user/hive/warehouse/mydb.db/employees/country=US/state=CA
```

对于INPATH子句中使用的文件路径还有一个限制，那就是这个路径下不可以包含任何文件夹。

Hive并不会验证用户装载的数据和表的模式是否匹配。然而，Hive会验证文件格式是否和表结构定义的一致。例如，如果表在创建时定义的存储格式是SEQUENCEFILE，那么转载进去的文件也应该是sequencefile格式的才行。

5.2 通过查询语句向表中插入数据

INSERT语句允许用户通过查询语句向目标表中插入数据。依旧使用前章中表employees作为例子，这里有一个俄亥俄州的例子，这里事先假设另一张名为staged_employees的表里已经有相关数据了。在表staged_employees中我们使用不同的名字来表示国家和州，分别称作cnty和st，这样做的原因稍后会进行说明。

```
INSERT OVERWRITE TABLE employees
PARTITION (country = 'US', state = 'OR')
SELECT * FROM staged_employees se
WHERE se.cnty = 'US' AND se.st = 'OR';
```

这里使用了OVERWRITE关键字，因此之前分区中的内容（如果是非分区表，就是之前表中的内容）将会被覆盖掉。

这里如果没有使用OVERWRITE关键字或者使用INTO关键字替换掉它的话，那么Hive将会以追加的方式写入数据而不会覆盖掉之前已经存在的内容。这个功能只有Hive v0.8.0版本以及之后的版本中才有。

这个例子展示了这个功能非常有用的一个常见的场景，即：数据已经存在于某个目录下，对于Hive来说其为一个外部表，而现在想将其导入到最终的分区表中。如果用户想将源表数据导入到一个具有不同记录格式（例如，具有不同的字段分割符）的目标表中的话，那么使用这种方式也是很好的。

然而，如果表staged_employees非常大，而且用户需要对65个州都执行这些语句，那么也就意味这需要扫描staged_employees表65次！Hive提供了另一种INSERT语法，可以只扫描一次输入数据，然后按多种方式进行划分。如下例子显示了如何为3个州创建表employees分区：

```
FROM staged_employees se
INSERT OVERWRITE TABLE employees
PARTITION (country = 'US', state = 'OR')
SELECT * WHERE se.cnty = 'US' AND se.st = 'OR'
INSERT OVERWRITE TABLE employees
PARTITION (country = 'US', state = 'CA')
SELECT * WHERE se.cnty = 'US' AND se.st = 'CA'
INSERT OVERWRITE TABLE employees
PARTITION (country = 'US', state = 'IL')
SELECT * WHERE se.cnty = 'US' AND se.st = 'IL';
```

这里我们使用了缩排使得每组句子看上去更清楚。从staged_employees表中读取的每条记录都会经过一条SELECT ... WHERE ...句子进行判断。这些句子都是独立进行判断的，这不是IF ... THEN ... ELSE ...结构！

事实上，通过使用这个结构，源表中的某些数据可以被写入目标表的多个分区中或者不被写入任一个分区中。

如果某条记录是满足某个SELECT ... WHERE ...语句的话，那么这条记录就会被写入到指定的表和分区中。简单明了地说，每个

INSERT子句，只要有需要，都可以插入到不同的表中，而那些目标表可以是分区表也可以是非分区表。

因此，输入的某些数据可能输出到多个输出位置而其他一些数据可能就被删除掉了！

当然，这里可以混合使用INSERT OVERWRITE 句式和 INSERT INTO句式。

动态分区插入

前面所说的语法中还是有一个问题，即：如果需要创建非常多的分区，那么用户就需要写非常多的SQL！不过幸运的是，Hive提供了一个动态分区功能，其可以基于查询参数推断出需要创建的分区名称。相比之下，到目前为止我们所看到的都是静态分区。

请看如下对前面例子修改后的句子：

```
INSERT OVERWRITE TABLE employees
PARTITION (country, state)
SELECT ... , se.cnty, se.st
FROM staged_employees se;
```

Hive根据SELECT语句中最后2列来确定分区字段country和state的值。这就是为什么在表staged_employees中我们使用了不同的命名，就是为了强调源表字段值和输出分区值之间的关系是根据位置而不是根据命名来匹配的。

假设表staged_employees中共有100个国家和州的话，执行完上面这个查询后，表employees就将会有100个分区！

用户也可以混合使用动态和静态分区。如下这个例子中指定了country字段的值为静态的US，而分区字段state是动态值：

```
INSERT OVERWRITE TABLE employees
PARTITION (country = 'US', state)
SELECT ... , se.cnty, se.st
FROM staged_employees se
WHERE se.cnty = 'US';
```

静态分区键必须出现在动态分区键之前。

动态分区功能默认情况下没有开启。开启后，默认是以“严格”模式执行的，在这种模式下要求至少有一列分区字段是静态的。这有助于阻止因设计错误导致查询产生大量的分区。例如，用户可能错误地使用时间戳作为分区字段，然后导致每秒都对应一个分区！而用户也许是期望按照天或者按照小时进行划分的。还有一些其他相关属性值用于限制资源利用。表5-1描述了这些属性。

表5-1 动态分区属性

属性名称	缺省值	描述
hive.exec.dynamic.partition	false	设置成true，表示开启动态分区功能
hive.exec.dynamic.partition.mode	strict	设置成nonstrict，表示允许所有分区都是动态的
hive.exec.max.dynamic.partitions.pernode	100	每个mapper或reducer可以创建的最大动态分区个数。如果某个mapper或reducerr尝试创建大于这个值的分区的话则会抛出一个致命错误信息
hive.exec.max.dynamic.partitions	+1000	一个动态分区创建语句可以创建的最大动态分区个数。如果超过这个值则会抛出一个致命错误信息
hive.exec.max.created.files	100000	全局可以创建的最大文件个数。有一个Hadoop计数器会跟踪记录创建了多少个文件，如果超过这个值则会抛出一个致命错误信息

因此，作为例子演示，前面我们使用的第一使用动态分区的例子看上去应该是像下面这个样子的，这里我们不过在使用前设置了一些期望的属性：

```
hive> set hive.exec.dynamic.partition=true;
hive> set hive.exec.dynamic.partition.mode=nonstrict;
hive> set hive.exec.max.dynamic.partitions.pernode=1000;

hive> INSERT OVERWRITE TABLE employees
> PARTITION (country, state)
> SELECT ..., se.cty, se.st
> FROM staged_employees se;
```

5.3 单个查询语句中创建表并加载数据

用户同样可以在一个语句中完成创建表并将查询结果载入这个表的操作：

```
CREATE TABLE ca_employees
AS SELECT name, salary, address
FROM employees
WHERE se.state = 'CA';
```

这张表只含有employee表中来自加利福尼亚州的雇员的name、salary和address3个字段的信息。新表的模式是根据SELECT语句来生成的。

使用这个功能的常见情况是从一个大的宽表中选取部分需要的数据集。

这个功能不能用于外部表。可以回想下使用ALTER TABLE语句可以为外部表“引用”到一个分区，这里本身没有进行数据“装载”，而是将元数据中指定一个指向数据的路径。

5.4 导出数据

我们如何从表中导出数据呢？如果数据文件恰好是用户需要的格式，那么只需要简单地拷贝文件夹或者文件就可以了：

```
hadoop fs -cp source_path target_path
```

否则，用户可以使用INSERT ... DIRECTORY ...，如下面例子所示：

```
INSERT OVERWRITE LOCAL DIRECTORY '/tmp/ca_employees'
SELECT name, salary, address
```

```
FROM employees
WHERE se.state = 'CA';
```

关键字OVERWRITE和LOCAL和前面的说明是一致的，路径格式也和通常的规则一致。一个或者多个文件将会被写入到/tmp/ca_employees，具体个数取决于调用的reducer个数。

这里指定的路径也可以写成全URL路径（例如，`hdfs://master-server/tmp/ca_employees`）。

不管在源表中数据实际是怎么存储的，Hive会将所有的字段序列化成字符串写入到文件中。Hive使用和Hive内部存储的表相同的编码方式来生成输出文件。

作为提醒，我们可以在hive CLI中查看结果文件内容：

```
hive> ! ls /tmp/ca_employees;
000000_0
hive> ! cat /tmp/payroll/000000_0
John Doe100000.0201 San Antonio CircleMountain ViewCA94040
Mary Smith80000.01 Infinity LoopCupertinoCA95014
...
```

是的，文件名是000000_0。如果有两个或者多个reducer来写输出的话，那么我们还可以看到其他相似命名的文件（例如，000001_1）。

如上输出内容看上去字段间没有分隔符，这是因为这里并没有把^A和^B显示出来。

和向表中插入数据一样，用户也是可以通过如下方式指定多个输出文件夹目录的：

```
FROM staged_employees se
INSERT OVERWRITE DIRECTORY '/tmp/or_employees'
SELECT * WHERE se.cty = 'US' and se.st = 'OR'
INSERT OVERWRITE DIRECTORY '/tmp/ca_employees'
SELECT * WHERE se.cty = 'US' and se.st = 'CA'
INSERT OVERWRITE DIRECTORY '/tmp/il_employees'
SELECT * WHERE se.cty = 'US' and se.st = 'IL';
```

对于定制输出的数据是有一些限制的（当然，除非自己写一个定制的OUTPUTFORMAT，这在”中有讲述）。为了格式化字段，Hive提

供了一些内置函数，其中包括那些用于字符串格式化的操作、例如转换操作，拼接输出操作等。详细信息请参考第6.1.4节中的“其他内置函数”。

表的字段分隔符可能是需要考量的。例如，如果其使用的是默认的^A分隔符，而用户又经常导出数据的话，那么可能使用逗号或者制表键作为分隔符会更合适。

另一种变通的方式是定义一个“临时”表，这个表的存储方式配置成期望的输出格式（例如，使用制表键作为字段分隔符）。然后再从这个临时表中查询数据，并使用INSERT OVERWTITE DIRECTORY将查询结果写入到这个表中。和很多关系型数据库不同的是，Hive中没有临时表的概念。用户需要手动删除任何创建了的但又不想长期保留的表。

第6章 HiveQL: 查询

在了解了可以通过多种方式来定义和格式化表之后，让我们来学习一下如何运行查询。当然，我们将假设你已经具备了SQL的相关知识。为了说明一些概念我们已经使用了一些查询，比如在第5章介绍过的加载查询数据到其他表中的操作。现在，我们将完善大部分的细节。一些特殊的主题将会在以后的其他章节中进行介绍。

对于具有SQL使用经验的用户来说比较熟悉的细节我们将进行得很快，而会专注于其和HiveQL有何差异，包括语法和特性的差异，以及对性能的影响。

6.1 SELECT... FROM语句

SELECT是SQL中的射影算子。FROM子句标识了从哪个表、视图或嵌套查询中选择记录（见第7章）。

对于一个给定的记录，SELECT指定了要保存的列以及输出函数需要调用的一个或多个列（例如，像count(*)这样的聚合函数）。我们再次回想下之前说明过的分区employees表：

```
CREATE TABLE employees (
  name      STRING,
  salary    FLOAT,
  subordinates  ARRAY<STRING>,
  deductions  MAP<STRING, FLOAT>,
  address    STRUCT<street:STRING, city:STRING, state:STRING, zip:INT>
)
PARTITIONED BY (country STRING, state STRING);
```

我们假定其和第3.3节“文本文件数据编码”中所介绍的具有相同的内容，也就是在美国伊利诺伊州（缩写为IL）中有4名员工。下面是对这个表进行的查询语句以及其输出内容：

```
hive> SELECT name, salary FROM employees;
John Doe    100000.0
Mary Smith   80000.0
Todd Jones   70000.0
Bill King    60000.0
```

下面两个查询是等价的。第2个版本使用了一个表别名e，在这个查询中不是很有用，但是如果查询中含有链接操作（参考第6.4节“JOIN语句”）的话，会涉及到多个不同的表，那就很有用了。

```
hive> SELECT name, salary FROM employees;
hive> SELECT e.name, e.salary FROM employees e;
```

当用户选择的列是集合数据类型时，Hive会使用JSON（Java脚本对象表示法）语法应用于输出。首先，让我们选择subordinates列，该列为一个数组，其值使用一个被括在[...]内的以逗号分隔的列表进行表示。注意，集合的字符串元素是加上引号的，而基本数据类型STRING的列值是不加引号的。

```
hive> SELECT name, subordinates FROM employees;
John Doe      ["Mary Smith", "Todd Jones"]
Mary Smith    ["Bill King"]
Todd Jones    []
Bill King     []
```

deductions列是一个MAP，其使用JSON格式来表达map，即使用一个被括在{...}内的以逗号分隔的键：值对列表进行表示：

```
hive> SELECT name, deductions FROM employees;
John Doe      {"Federal Taxes":0.2, "State Taxes":0.05, "Insurance":0.1}
Mary Smith    {"Federal Taxes":0.2, "State Taxes":0.05, "Insurance":0.1}
Todd Jones    {"Federal Taxes":0.15, "State Taxes":0.03, "Insurance":0.1}
Bill King     {"Federal Taxes":0.15, "State Taxes":0.03, "Insurance":0.1}
```

最后，address列是一个STRUCT，其也是使用JSON map格式进行表示的：

```
hive> SELECT name, address FROM employees;
John Doe      {"street":"1 Michigan Ave.", "city":"Chicago", "state":"IL",
"zip":60600}
Mary Smith    {"street":"100 Ontario St.", "city":"Chicago", "state":"IL",
"zip":60601}
Todd Jones    {"street":"200 Chicago Ave.", "city":"Oak
Park", "state":"IL", "zip":60700}
Bill King     {"street":"300 Obscure
Dr.", "city":"Obscuria", "state":"IL", "zip":60100}
```

接下来，让我们看看如何引用集合数据类型中的元素。

首先，数组索引是基于0的，这个和在Java中是一样的。这里是一个选择subordinates数组中的第1个元素的查询：

```
hive> SELECT name, subordinates[0] FROM employees;
John Doe    Mary Smith
Mary Smith  Bill King
Todd Jones   NULL
Bill King    NULL
```

注意，引用一个不存在的元素将会返回NULL。同时，提取出的 STRING数据类型的值将不再加引号！

为了引用一个MAP元素，用户还可以使用ARRAY[...]语法，但是使用的是键值而不是整数索引：

```
hive> SELECT name, deductions["State Taxes"] FROM employees;
John Doe      0.05
Mary Smith    0.05
Todd Jones    0.03
Bill King     0.03
```

最后，为了引用STRUCT中的一个元素，用户可以使用“点”符号，类似于前面提到的“表的别名.列名”这样的用法：

```
hive> SELECT name, address.city FROM employees;
John Doe      Chicago
Mary Smith    Chicago
Todd Jones    Oak Park
Bill King     Obscuria
```

WHERE子句中同样可以使用这些引用方式，这个我们将在第6.2节“WHERE语句”中进行讨论。

6.1.1 使用正则表达式来指定列

我们甚至可以使用正则表达式来选择我们想要的列。下面的查询将会从表stocks中选择symbol列和所有列名以price作为前缀的列^[1]：

```
hive> SELECT symbol, `price.*` FROM stocks;
AAPL      195.69 197.88 194.0  194.12 194.12
AAPL      192.63 196.0  190.85 195.46 195.46
AAPL      196.73 198.37 191.57 192.05 192.05
AAPL      195.17 200.2  194.42 199.23 199.23
```

```
AAPL    195.91 196.32 193.38 195.86 195.86
...
...
```

我们将在第6.2.3节“LIKE和RLIKE”中继续讨论在Hive中如何使用正则表达式。

6.1.2 使用列值进行计算

用户不但可以选择表中的列，还可以使用函数调用和算术表达式来操作列值。

例如，我们可以查询得到转换为大写的雇员姓名、雇员对应的薪水、需要缴纳的联邦税收比例以及扣除税收后再进行取整所得的税后薪资。我们甚至可以通过调用内置函数`map_values`提取出`deductions`字段`map`类型值的所有元素，然后使用内置的`sum`函数对`map`中所有元素进行求和运算。

以下这个查询因为太长，所以我们将它划分成两行显示了。注意下第2行Hive所使用的提示符，那是一个缩进了的大于符号（>）：

```
hive> SELECT upper(name), salary, deductions["Federal Taxes"],
> round(salary * (1 - deductions["Federal Taxes"])) FROM employees;
JOHN DOE    100000.0    0.2    80000
MARY SMITH   80000.0    0.2    64000
TODD JONES   70000.0    0.15   59500
BILL KING    60000.0    0.15   51000
```

让我们先来讨论一下算术运算符，然后再讨论如何在表达式中使用这些算术运算符。

6.1.3 算术运算符

Hive中支持所有典型的算术运算符。表6-1描述了具体的细节。

表6-1 算术运算符

运算符	类型	描述

运算符	类型	描述
$A + B$	数值	A和B相加
$A - B$	数值	A减去B
$A * B$	数值	A和B相乘
A / B	数值	A除以B。如果能整除，那么返回商数（译者注：商数是一个整数，表示在不考虑有余数的情况下，除数可以除被除数的次数）
$A \% B$	数值	A除以B的余数
$A \& B$	数值	A和B按位取与
$A B$	数值	A和B按位取或
$A ^ B$	数值	A和B按位取亦或
$\sim A$	数值	A按位取反

算术运算符接受任意的数值类型。不过，如果数据类型不同，那么两种类型中值范围较小的那个数据类型将转换为其他范围更广的数据类型。（范围更广在某种意义上就是指一个类型具有更多的字节从而可以容纳更大范围的值。）例如，对于INT和BIGINT运算，INT会将类型转换提升为BIGINT。对于INT和FLOAT运算，INT将提升为FLOAT。可以注意到我们的查询语句中包含有`(1 - deductions[...])`这个运算。因为字段deductions是FLOAT类型的，因此数字1会提升为FLOAT类型。

当进行算术运算时，用户需要注意数据溢出或数据下溢问题。Hive遵循的是底层Java中数据类型的规则，因此当溢出或下溢发生时计算结果不会自动转换为更广泛的数据类型。乘法和除法最有可能会引发这个问题。

用户需要注意所使用的数值数据的数值范围，并确认实际数据是否接近表模式中定义的数据类型所规定的数值范围上限或者下限，还需要确认人们可能对这些数据进行什么类型的计算。

如果用户比较担心溢出和下溢，那么可以考虑在表模式中定义使用范围更广的数据类型。不过这样做的缺点是每个数据值会占用更多额外的内存。

用户也可以使用特定的表达式将值转换为范围更广的数据类型。详细信息请参考随后的表 6-2 和第6.8节“类型转换”。

有时使用函数将数据值按比例从一个范围缩放到另一个范围也是很有用的，例如按照10次方幂进行除法运算或取log值（指数值），等等。这种数据缩放也适用于某些机器学习计算中，用以提高算法的准确性和数值稳定性。

6.1.4 使用函数

我们前面的那个示例中还使用到了一个内置数学函数`round()`，这个函数会返回一个DOUBLE类型的最近整数。

1. 数学函数

表 6-2 中描述了 Hive 内置数学函数，这是 Hive v0.8.0 版本中所提供的，而且是用于处理单个列的数据的。

表6-2 数学函数

返回值类型	样式	描述
BIGINT	<code>round(DOUBLE d)</code>	返回DOUBLE型d的BIGINT类型的近似值
DOUBLE	<code>round(DOUBLE d, INT n)</code>	返回DOUBLE型d的保留n位小数的DOUBLE型的近似值
BIGINT	<code>floor(DOUBLE d)</code>	d是DOUBLE类型的，返回 $\leq d$ 的最大BIGINT型值
BIGINT	<code>ceil(DOUBLE d)</code> <code>ceiling(DOUBLE d)</code>	d是DOUBLE类型的，返回 $\geq d$ 的最小BIGINT型值
DOUBLE	<code>rand()</code> <code>rand(INT seed)</code>	每行返回一个DOUBLE型随机数，整数seed是随机因子
DOUBLE	<code>exp(DOUBLE d)</code>	返回 e 的 d 幂次方，返回的是个DOUBLE型值
DOUBLE	<code>ln(DOUBLE d)</code>	以自然数为底d的对数，返回DOUBLE型值
DOUBLE	<code>log10(DOUBLE d)</code>	以10为底d的对数，返回DOUBLE型值
DOUBLE	<code>log2(DOUBLE d)</code>	以2为底d的对数，返回DOUBLE型值
DOUBLE	<code>log(DOUBLE base, DOUBLE d)</code>	以base为底d的对数，返回DOUBLE型值,其中base和d都是DOUBLE型的

返回值类型	样式	描述
DOUBLE	pow(DOUBLE d, DOUBLE p) power(DOUBLE d, DOUBLE p)	计算d的p次幂, 返回DOUBLE值, 其中d和p都是DOUBLE型的
DOUBLE	sqrt(DOUBLE d)	计算d的平方根, 其中d是DOUBLE型的
STRING	bin(DOUBLE i)	计算二进制值i的STRING类型值, 其中i是BIGINT类型的
STRING	hex(BIGINT i)	计算十六进制值i的STRING类型值, 其中i是BIGINT类型的
STRING	hex(STRING str)	计算十六进制表达的值str的STRING类型值
STRING	hex(BINARY b)	计算二进制表达的值b的STRING类型值 (Hive 0.12.0版本新增)
STRING	unhex(STRING i)	hex(STRING str)的逆方法
STRING	conv(BIGINT num, INT from_base, INT to_base)	将BIGINT类型的num从from_base进制转换成to_base进制, 并返回STRING类型结果
STRING	conv(STRING num, INT from_base, INT to_base)	将STRING类型的num从from_base进制转换成to_base进制, 并返回STRING类型结果
DOUBLE	abs(DOUBLE d)	计算DOUBLE型值d的绝对值, 返回结果也是DOUBLE型的

返回值类型	样式	描述
INT	pmod(INT i1, INT i2)	INT值i1对INT值i2取模, 结果也是INT型的
DOUBLE	pmod(DOUBLE d1, DOUBLE d2)	DOUBLE值d1对DOUBLE值d2取模, 结果也是DOUBLE型的
DOUBLE	sin(DOUBLE d)	在弧度度量中, 返回DOUBLE型值d的正弦值, 结果是DOUBLE型的
DOUBLE	asin(DOUBLE d)	在弧度度量中, 返回DOUBLE型值d的反正弦值, 结果是DOUBLE型的
DOUBLE	cos(DOUBLE d)	在弧度度量中, 返回DOUBLE型值d的余弦值, 结果是DOUBLE型的
DOUBLE	acos(DOUBLE d)	在弧度度量中, 返回DOUBLE型值d的反余弦值, 结果是DOUBLE型的
DOUBLE	tan(DOUBLE d)	在弧度度量中, 返回DOUBLE型值d的正切值, 结果是DOUBLE型的
DOUBLE	atan(DOUBLE d)	在弧度度量中, 返回DOUBLE型值d的反正切值, 结果是DOUBLE型的
DOUBLE	degrees(DOUBLE d)	将DOUBLE型弧度值d转换成角度值, 结果是DOUBLE型的
DOUBLE	radians(DOUBLE d)	将DOUBLE型角度值d转换成弧度值, 结果是DOUBLE型的
INT	positive(INT i)	返回INT型值i(其等价的有效表达式是+i)

返回值类型	样式	描述
DOUBLE	positive(DOUBLE d)	返回DOUBLE型值d(其等价的有效表达式是+d)
INT	negative(INT i)	返回INT型值i的负数(其等价的有效表达式是-i)
DOUBLE	negative(DOUBLE d)	返回DOUBLE型值d的负数(其等价的有效表达式是-d)
FLOAT	sign(DOUBLE d)	如果DOUBLE型值d是正数的话, 则返回FLOAT值1.0; 如果d是负数的话, 则返回-1.0; 否则返回0.0
DOUBLE	e()	数学常数e, 也就是超越数, 的DOUBLE型值
DOUBLE	pi()	数学常数pi, 也就是圆周率, 的DOUBLE型值

需要注意的是函数floor、round和ceil（“向上取整”）输入的是DOUBLE类型的值, 而返回值是BIGINT类型的, 也就是将浮点型数转换成整型了。在进行数据类型转换时, 这些函数是首选的处理方式, 而不是使用前面我们提到过的cast类型转换操作符。

同样地, 也存在基于不同的底（例如十六进制）将整数转换为字符串的函数。

2. 聚合函数

聚合函数是一类比较特殊的函数, 其可以对多行进行一些计算, 然后得到一个结果值。更确切地说, 这是用户自定义聚合函数, 在第13.4节“聚合函数”中会有详细的介绍。这类函数中最有名的两个例子就是count和avg。函数count用于计算有多少行数据（或者某列有多少值）, 而函数avg可以返回指定列的平均值。

这里是一个查询示例表employees中有多少雇员，以及计算这些雇员平均薪水的HiveQL语句：

```
hive> SELECT count(*), avg(salary) FROM employees;
4 77500.0
```

当我们在第6.3节“GROUP BY语句”中讨论GROUP BY时将会看到其他的例子。

表6-3 列举了Hive的内置聚合函数。

表6-3 聚合函数

返回值类型	样式	描述
BIGINT	count(*)	计算总行数，包括含有NULL值的行
BIGINT	count(expr)	计算提供的expr表达式的值非NULL的行数
BIGINT	count(DISTINCT expr[, expr_...])	计算提供的expr表达式的值排重后非NULL的行数
DOUBLE	sum(col)	计算指定行的值的和
DOUBLE	sum(DISTINCT col)	计算排重后值的和
DOUBLE	avg(col)	计算指定行的值的平均值
DOUBLE	avg(DISTINCT col)	计算排重后的值的平均值
DOUBLE	min(col)	计算指定行的最小值

返回值类型	样式	描述
DOUBLE	max(col)	计算指定行的最大值
DOUBLE	variance(col), var_pop(col)	返回集合col中的一组数值的方差
DOUBLE	var_samp(col)	返回集合col中的一组数值的样本方差
DOUBLE	stddev_pop(col)	返回一组数值的标准偏差
DOUBLE	stddev_samp(col)	返回一组数值的标准样本偏差
DOUBLE	covar_pop(col1, col2)	返回一组数值的协方差
DOUBLE	covar_samp(col1, col2)	返回一组数值的样本协方差
DOUBLE	corr(col1, col2)	返回两组数值的相关系数
DOUBLE	percentile(BIGINT int_expr, p)	int_expr在p (范围是: [0,1]) 处的对应的百分比, 其中p是一个DOUBLE型数值
ARRAY<DOUBLE>	percentile(BIGINT int_expr, ARRAY(P1[, P2]...))	int_expr在p (范围是: [0,1]) 处的对应的百分比, 其中p是一个DOUBLE型数组
DOUBLE	percentile_approx (DOUBLE col, p[, NB])	col在p (范围是: [0,1]) 处的对应的百分比, 其中p是一个DOUBLE型数值, NB是用于估计的直方图中的仓库数量 (默认是10000)

返回值类型	样式	描述
ARRAY<DOUBLE>	percentile_approx (DOUBLE col, ARRAY (p1[, p2]...[, NB]))	col在p (范围是: [0,1]) 处的对应的百分比, 其中p是一个DOUBLE型数组, NB是用于估计的直方图中的仓库数量 (默认是10000)
ARRAY<STRUCT{'x','y'}>	histogram_numeric(col, NB)	返回NB数量的直方图仓库数组, 返回结果中的值x是中心, 值y是仓库的高
ARRAY	collect_set(col)	返回集合col元素排重后的数组

通常, 可以通过设置属性hive.map.aggr值为true来提高聚合的性能, 如下所示:

```
hive> SET hive.map.aggr=true;
hive> SELECT count(*), avg(salary) FROM employees;
```

正如这个例子所展示的, 这个设置会触发在map阶段进行的“顶级”聚合过程。(非顶级的聚合过程将会在执行一个GROUP BY后进行。) 不过, 这个设置将需要更多的内存。

如表6-3所示, 多个函数都可以接受DISTINCT ... 表达式。例如, 我们可以通过这种方式计算排重后的孤僻交易码个数:

```
hive> SELECT count(DISTINCT symbol) FROM stocks;
0
```



警告

等一下, 结果为0? 当使用count(DISTINCT col)而同时col是分区列时存在这个bug。对于纳斯达克和纽约证券交易所来说答案

应该是743，至少在我们使用的2010年初infochimps.org提供的数据集中是这个数。

注意，在Hive wiki中，目前不允许在一个查询语句中使用多于一个的函数(*DISTINCT*...)表达式。例如，下面这个查询语句按说是不允许的，但是实际上是可以执行的：

```
hive> SELECT count(DISTINCT ymd), count(DISTINCT volume) FROM stocks;  
12110 26144
```

因此，从查询结果中可以看到有12 110个交易日的数据，即超过40年的价值。

3. 表生成函数

与聚合函数“相反的”一类函数就是所谓的表生成函数，其可以将单列扩展成多列或者多行。我们将在第13.5节“表生成函数”中更全面地讨论这类函数，这里我们将简要地讨论下，然后列举出Hive目前所提供的某些内置表生成函数。

下面我们通过一个例子来进行讲解。如下的这个查询语句将employees表中每行记录中的subordinates字段内容转换成0个或者多个新的记录行。如果某行雇员记录subordinates字段内容为空的话，那么将不会产生新的记录；如果不为空的话，那么这个数组的每个元素都将产生一行新记录：

```
hive> SELECT explode(subordinates) AS sub FROM employees;  
Mary Smith  
Todd Jones  
Bill King
```

上面的查询语句中，我们使用AS sub子句定义了列别名sub。当使用表生成函数时，Hive要求使用列别名。用户可能需要了解其他许多的特性细节才能正确地使用这些函数。第13.5节“表生成函数”中，我们将进行详细的讨论。

表6-4列举了Hive内置的表生成函数。

下面是一个使用函数parse_url_tuple的例子，其中我们假设存在一张名为url_table的表，而且表中含有一个名为url的列，列中存储有很

多网址:

```
SELECT parse_url_tuple(url, 'HOST', 'PATH', 'QUERY') as (host, path, query)
FROM url_table;
```

表6-4 表生成函数

返回值类型	样式	描述
N行结果	explode(ARRAY array)	返回0到多行结果，每行都对应输入的array数组中的一个元素
N行结果	explode(MAP map)	返回0到多行结果，每行对应每个map键-值对，其中一个字段是map的键，另一个字段对应map的值 (Hive 0.8.0版本新增)
数组的类型	explode(ARRAY<TYPE> a)	对于a中的每个元素，explode()会生成一行记录包含这个元素
结果插入表中	inline(ARRAY<STRUCT [, STRUCT]>)	将结构体数组提取出来并插入到表中 (Hive 0.10.0版本新增)
TUPLE	json_tuple(STRING jsonStr, p1, p2, ..., pn)	本函数可以接受多个标签名称，对输入的JSON字符串进行处理，这个get_json_object这个UDF类似，不过更高效，其通过一次调用就可以获得多个键值
TUPLE	parse_url_tuple(url, partname1, partname2, ..., partnameN) 其中 N >= 1	从URL中解析出N个部分信息。其输入参数是: URL，以及多个要抽取的部分的名称。所有输入的参数的类型都是STRING。部分名称是大小写敏感的，而且不应该包含有空格: HOST, PATH, QUERY, REF,PROTOCOL, AUTHORITY, FILE, USERINFO,QUERY:<KEY_NAME>
N行结果	stack(INT n, col1, ..., colM)	把M列转换成N行，每行有M/N个字段。其中n必须是个常数

根据下面的表6-5，用户可以比较下函数parse_url_tuple和函数parse_url的区别。

4. 其他内置函数

表6-5中描述了Hive中其余的内置函数，这些函数用于处理字符串、Map、数组、JSON和时间戳，包含或者没有包含最近引入的TIMESTAMP数据类型（参考第3.1节“基本数据类型”中的内容）。

表6-5 其他内置函数

返回值类型	样式	描述
STRING	ascii(STRING s)	返回字符串s中首个ASCII字符的整数值
STRING	base64(BINARY bin)	将二进制值bin转换成基于64位的字符串(Hive 0.12.0版本新增)
BINARY	binary(STRING s) binary(BINARY b)	将输入的值转换成二进制值(Hive 0.12.0版本新增)
返回类型就是type定义的类型	cast(<expr> as <type>)	将expr转换成type类型的。例如cast('1' as BIGINT)将会将字符串‘1’转换成BIGINT数值类型。如果转换过程失败，则返回NULL
STRING	concat(BINARY s1, BINARY s2, ...)	将二进制字节码按次序拼接成一个字符串 (Hive 0.12.0版本新增)
STRING	concat(STRING s1, STRING s2, ...)	将字符串s1,s2等拼接成一个字符串。例如，concat('ab','cd')的结果是‘abcd’

返回值类型	样式	描述
STRING	concat_ws(STRING separator, STRING s1, STRING s2, ...)	和concat类似，不过是使用指定的分隔符进行拼接的
STRING	concat_ws(BINARY separator, BINARY s1, STRING s2, ...)	和concat类似，不过是使用指定的分隔符进行拼接的 (Hive 0.12.0版本新增)
ARRAY<STRUCT <STRING,DOUBLE>>	context_ngrams(array<array<string>>, array<string>, int K, int pf)	和ngrams类似，但是从每个外层数组的第二个单词数组来查找前K个字尾
STRING	decode(BINARY bin, STRING charset)	使用指定的字符集charset将二进制值bin解码成字符串(支持的字符集有:'US_ASCII', 'ISO-8859-1', 'UTF-8', 'UTF-16BE', 'UTF-16LE', 'UTF-16').如果任一输入参数为NULL，则结果为NULL(Hive 0.12.0版本新增)
BINARY	encode(STRING src, STRING charset)	使用指定的字符集charset将字符串src编码成二进制值(支持的字符集有:'US_ASCII', 'ISO-8859-1', 'UTF-8', 'UTF-16BE', 'UTF-16LE', 'UTF-16').如果任一输入参数为NULL，则结果为NULL(Hive 0.12.0版本新增)
INT	find_in_set(STRING s, STRING commaSeparatedString)	返回在以逗号分隔的字符串中s出现的位置，如果没有找到则返回NULL
STRING	format_number(NUMBER x, INT d)	将数值x转换成'#,##,##.##'格式字符串，并保留d位小数。如果d为0，那么输出值就没有小数点后面的值

返回值类型	样式	描述
STRING	<code>get_json_object (STRING json_string, STRING path)</code>	从给定路径上的JSON字符串中 抽取出JSON对象，并返回这个 对象的JSOM字符串形式。如果 输入的JSON字符串是非法的， 则返回NULL
BOOLEAN	<code>in</code>	例如， <code>test in (val1, val2, ...)</code> ，其 表示如果 <code>test</code> 值等于后面列表中 的任一值的话，则返回 <code>true</code>
BOOLEAN	<code>in_file(STRING s, STRING filename)</code>	如果文件名为 <code>filename</code> 的文件中 有完整一行数据和字符串 <code>s</code> 完全 匹配的话，则返回 <code>true</code>
INT	<code>instr(STRING str, STRING substr)</code>	查找字符串 <code>str</code> 中子字符串 <code>substr</code> 第一次出现的位置
INT	<code>length(STRING s)</code>	计算字符串 <code>s</code> 的长度
INT	<code>locate(STRING substr, STRING str [,INT pos])</code>	查找在字符串 <code>str</code> 中的 <code>pos</code> 位置后 字符串 <code>substr</code> 第一次出现的位置
STRING	<code>lower(STRING s)</code>	将字符串中所有字母转换成小 写字母。例如， <code>upper('hIvE')</code> 的 结果是 <code>'hive'</code>
STRING	<code>lcase(STRING s)</code>	和 <code>lower()</code> 一样
STRING	<code>lpad(STRING s, INT len, STRING pad)</code>	从左边开始对字符串 <code>s</code> 使用字符串 <code>pad</code> 进行填充，最终达到 <code>len</code> 长 度为止。如果字符串 <code>s</code> 本身长度 比 <code>len</code> 大的话，那么多余的部分 会被去除掉

返回值类型	样式	描述
STRING	<code>ltrim(STRING s)</code>	将字符串s前面出现的空格全部去除掉。例如 <code>trim(' hive ')</code> 的结果是‘hive ’
ARRAY<STRUCT<STRING,DOUBLE>>	<code>ngrams(ARRAY<ARRAY<string>>, INT N, INT K, INT pf)</code>	估算文件中前K个字尾。pf是精度系数
STRING	<code>parse_url(STRING url, STRING partname [, STRING key])</code>	从URL中抽取指定部分的内容。参数url表示一个URL字符串，参数partname表示要抽取的部分名称，其是大小写敏感的，可选的值有：HOST, PATH, QUERY, REF, PROTOCOL, AUTHORITY, FILE, USERINFO, QUERY:<key>。如果partname是QUERY的话，那么还需要指定第三个参数key。可以和表 6-4中的 <code>parse_url_tuple</code> 对比下
STRING	<code>printf(STRING format, Obj ... args)</code>	按照printf风格格式化输出输入的字符串（Hive 0.9.0版本新增）
STRING	<code>regexp_extract(STRING subject, STRING regex_pattern, STRING index)</code>	抽取字符串subject中符合正则表达式 <code>regex_pattern</code> 的第index个部分的子字符串
STRING	<code>regexp_replace(STRING s, STRING regex, STRING replacement)</code>	按照Java正则表达式 <code>regex</code> 将字符串s中符合条件的部分替换成 <code>replacement</code> 所指定的字符串a。如果 <code>replacement</code> 部分是空的话，那么符合正则的部门就会被去除掉。例如 <code>regexp_replace('hive', '[ie]', 'z')</code> 的结果是‘hzvz’

返回值类型	样式	描述
STRING	repeat(STRING s, INT n)	重复输出n次字符串s
STRING	reverse(STRING s)	反转字符串
STRING	rpad(STRING s, INT len, STRING pad)	从右边开始对字符串s使用字符串pad进行填充, 最终达到len长度为止。如果字符串s本身长度比len大的话, 那么多余的部分会被去除掉
STRING	rtrim(STRING s)	将字符串s后面出现的空格全部去除掉。例如trim(' hive ')的结果是‘ hive ’
ARRAY<ARRAY<STRING>>	sentences(STRING s, STRING lang, STRING locale)	将输入字符串s转换成句子数组, 每个句子又由一个单词数组构成。参数lang和locale是可选的, 如果没有使用的, 则使用默认的本地化信息
INT	size(MAP<K,V>)	返回MAP中元素的个数
INT	size(ARRAY<T>)	返回数组ARRAY的元素个数
STRING	space(INT n)	返回n个空格
ARRAY<STRING>	split(STRING s, STRING pattern)	按照正则表达式pattern分割字符串s, 并将分割后的部分以字符串数组的方式返回

返回值类型	样式	描述
MAP<STRING , STRING>	<code>str_to_map (STRING s,STRING delim1, STRING delim2)</code>	将字符串s按照指定分隔符转换成Map, 第一个参数是输入的字符串, 第二个参数是键值对之间的分隔符, 第三个分隔符是键和值之间的分隔符
STRING	<code>substr(STRING s,STRING start_index)substring (STRING s,STRING start_index)</code>	对于字符串s, 从start位置开始截取length长度的字符串, 作为子字符串。例如 <code>substr('abcdefg',3,2)</code> 的结果是‘cd’
STRING	<code>substr(BINARY s,STRING start_index)substring (BINARY s,STRING start_index)</code>	对于二进制字节值s, 从start位置开始截取length长度的字符串, 作为子字符串 (Hive 0.12.0新增)
STRING	<code>translate(STRING input, STRING from, STRING to)</code>	
STRING	<code>trim(STRING A)</code>	将字符串s前后出现的空格全部去除掉。例如 <code>trim(' hive ')</code> 的结果是‘hive’
BINARY	<code>unbase64(STRING str)</code>	将基于64位的字符串str转换成二进制值 (Hive 0.12.0版本新增)
STRING	<code>upper(STRING A) ucase(STRING A)</code>	将字符串中所有字母转换成大写字母。例如, <code>upper('hIvE')</code> 的结果是‘HIVE’

返回值类型	样式	描述
STRING	<code>from_unixtime (BIGINT unixtime[, STRING format])</code>	将时间戳秒数转换成UTC时间，并用字符串表示，可以通过format规定的时间格式，指定输出的时间格式
BIGINT	<code>unix_timestamp()</code>	获取当前本地时区下的当前时间戳
BIGINT	<code>unix_timestamp (STRING date)</code>	输入的时间字符串格式必须是yyyy-MM-dd HH:mm:ss，如果不符则返回0，如果符合则将此时间字符串转换成Unix时间戳。例如： <code>unix_timestamp('2009-03-20 11:30:01') = 1237573801</code>
BIGINT	<code>unix_timestamp (STRING date, STRING pattern)</code>	将指定时间字符串格式字符串转换成Unix时间戳，如果格式不对则返回0。例如： <code>unix_timestamp('2009-03-20', 'yyyy-MM-dd') = 1237532400</code>
STRING	<code>to_date(STRING timestamp)</code>	返回时间字符串的日期部分， 例如： <code>to_date("1970-01-01 00:00:00") = "1970-01-01"</code>
INT	<code>year(STRING date)</code>	返回时间字符串中的年份并使用INT类型表示。例如： <code>year("1970-01-01 00:00:00") = 1970, year("1970-01-01") = 1970</code>
INT	<code>month(STRING date)</code>	返回时间字符串中的月份并使用INT类型表示。例如： <code>month("1970-11-01 00:00:00") = 11, month("1970-11-01") = 11</code>

返回值类型	样式	描述
INT	day(STRING date) dayofmonth(STRING date)	返回时间字符串中的天并使用INT类型表示。例如:day("1970-11-01 00:00:00") = 1, day("1970-11-01") = 1
INT	hour(STRING date)	返回时间戳字符串中的小时并使用INT类型表示。例如:hour('2009-07-30 12:58:59') = 12, hour('12:58:59') = 12
INT	minute(STRING date)	返回时间字符串中的分钟数
INT	second(STRING date)	返回时间字符串中的秒数
INT	weekofyear(STRING date)	返回时间字符串位于一年中第几个周内。例如:weekofyear("1970-11-01 00:00:00") = 44, weekofyear("1970-11-01") = 44
INT	datediff(STRING enddate, STRING startdate)	计算开始时间startdata到结束时间enddate相差的天数。例如:datediff('2009-03-01', '2009-02-27') = 2
STRING	date_add(STRING startdate, INT days)	为开始时间startdate增加days天。例如: date_add('2008-12-31', 1) = '2009-01-01'
STRING	date_sub(STRING startdate, INT days)	从开始时间startdate中减去days天。例如: date_sub('2008-12-31', 1) = '2008-12-30'

返回值类型	样式	描述
TIMESTAMP	from_utc_timestamp (TIMESTAMP timestamp, STRING timezone)	如果给定的时间戳并非UTC，则将其转化成指定的时区下的时间戳 (Hive 0.8.0版本新增)
TIMESTAMP	to_utc_timestamp (TIMESTAMP timestamp, STRING timezone)	如果给定的时间戳是指定的时区下的时间戳，则将其转化成UTC下的时间戳 (Hive 0.8.0版本新增)

需要注意的是，和时间相关的函数输入的是整型或者字符串类型参数。对于Hive v0.8.0版本，这些函数同样接受TIMESTAMP类型参数，同时为了向后兼容，它们还将继续支持之前的整型和字符串类型参数。

6.1.5 LIMIT语句

典型的查询会返回多行数据。LIMIT子句用于限制返回的行数：

```
hive> SELECT upper(name), salary, deductions["Federal Taxes"],  
> round(salary * (1 - deductions["Federal Taxes"])) FROM employees  
> LIMIT 2;  
JOHN DOE    1000000.0  0.2  80000  
MARY SMITH   800000.0  0.2  64000
```

6.1.6 列别名

前面的示例查询语句可以认为是返回一个由新列组成的新关系，其中有些新产生的结果列对于表employees来说是不存在的。通常有必要给这些新产生的列起一个名称，也就是别名。下面这个例子对之前的那个查询进行了修改，为第3个和第4个字段起了别名，别名分别为fed_taxes和salary_minus_fed_taxes。

```
hive> SELECT upper(name), salary, deductions["Federal Taxes"] as fed_taxes,  
> round(salary * (1 - deductions["Federal Taxes"])) as salary_minus_fed_taxes  
> FROM employees LIMIT 2;  
JOHN DOE    1000000.0 0.2 80000  
MARY SMITH   800000.0 0.2 64000
```

6.1.7 嵌套SELECT语句

对于嵌套查询语句来说，使用别名是非常有用的。下面，我们使用前面的示例作为一个嵌套查询：

```
hive> FROM (
>   SELECT upper(name), salary, deductions["Federal Taxes"] as fed_taxes,
>   round(salary * (1 - deductions["Federal Taxes"])) as salary_
minus_fed_taxes
>   FROM employees
> ) e
> SELECT e.name, e.salary_minus_fed_taxes
> WHERE e.salary_minus_fed_taxes > 70000;
JOHN DOE 100000.0 0.2 80000
```

从这个嵌套查询语句中可以看到，我们将前面的结果集起了个别名，称之为e，在这个语句外面嵌套查询了name和salary_minus_fed_taxes两个字段，同时约束后者的值要大于70,000。（在后面的第6.2节“WHERE语句”中我们将会讨论WHERE相关内容。）

6.1.8 CASE ... WHEN ... THEN 句式

CASE ... WHEN ... THEN语句和if条件语句类似，用于处理单个列的查询结果。

例如：

```
hive> SELECT name, salary,
>   CASE
>     WHEN salary < 50000.0 THEN 'low'
>     WHEN salary >= 50000.0 AND salary < 70000.0 THEN 'middle'
>     WHEN salary >= 70000.0 AND salary < 100000.0 THEN 'high'
>     ELSE 'very high'
>   END AS bracket FROM employees;
John Doe      100000.0 very high
Mary Smith     80000.0 high
Todd Jones     70000.0 high
Bill King      60000.0 middle
Boss Man       200000.0 very high
Fred Finance   150000.0 very high
Stacy Accountant 60000.0 middle
...
```

6.1.9 什么情况下Hive可以避免进行MapReduce

对于本书中的查询，如果用户进行过执行的话，那么可能会注意到大多数情况下查询都会触发一个MapReduce任务（job）。Hive中对某些情况的查询可以不必使用MapReduce，也就是所谓的本地模式，例如：

```
SELECT * FROM employees;
```

在这种情况下，Hive可以简单地读取employees对应的存储目录下的文件，然后输出格式化后的内容到控制台。

对于WHERE语句中过滤条件只是分区字段这种情况（无论是否使用LIMIT语句限制输出记录条数），也是无需MapReduce过程的。

```
SELECT * FROM employees
WHERE country='US' AND state='CA'
LIMIT 100;
```

此外，如果属性hive.exec.mode.local.auto的值设置为true的话，Hive还会尝试使用本地模式执行其他的操作：

```
set hive.exec.mode.local.auto=true;
```

否则，Hive使用MapReduce来执行其他所有的查询。



提示

相信我，最好将set hive.exec.mode.local.auto=true;这个设置增加到你的\$HOME/.hiverc配置文件中。

6.2 WHERE语句

SELECT语句用于选取字段，WHERE语句用于过滤条件，两者结合使用可以查找到符合过滤条件的记录。和SELECT语句一样，在介绍WHERE语句之前我们已经在很多的简单例子中使用过它了。之前都是假定用户是见过这样的语句的，现在我们将更多地探讨一些细节。

WHERE语句使用谓词表达式，对于列应用在谓词操作符上的情况，稍后我们将进行讨论。有几种谓词表达式可以使用AND和OR相连接。当谓词表达式计算结果为true时，相应的行将被保留并输出。

我们刚才就使用了下面这个例子来限制查询的结果必须是美国的加利福尼亚州的：

```
SELECT * FROM employees
WHERE country = 'US' AND state = 'CA';
```

谓词可以引用和SELECT语句中相同的各种对于列值的计算。这里我们修改下之前的对于联邦税收的查询，过滤保留那些工资减去联邦税后总额大于70, 000的查询结果：

```
hive> SELECT name, salary, deductions["Federal Taxes"],
>     salary * (1 - deductions["Federal Taxes"])
>   FROM employees
> WHERE round(salary * (1 - deductions["Federal Taxes"])) > 70000;
John Doe      100000.0  0.2    80000.0
```

这个查询语句有点难看，因为第2行的那个复杂的表达式和WHERE后面的表达式是一样的。下面的查询语句通过使用一个列别名消除了这里表达式重复的问题，但是不幸的是它不是有效的：

```
hive> SELECT name, salary, deductions["Federal Taxes"],
>     salary * (1 - deductions["Federal Taxes"]) as salary_minus_fed_taxes
>   FROM employees
> WHERE round(salary_minus_fed_taxes) > 70000;
FAILED: Error in semantic analysis: Line 4:13 Invalid table alias or
column reference 'salary_minus_fed_taxes': (possible column names are:
name, salary, subordinates, deductions, address)
```

正如错误信息所提示的，不能在WHERE语句中使用列别名。不过，我们可以使用一个嵌套的SELECT语句：

```
hive> SELECT e.* FROM
> (SELECT name, salary, deductions["Federal Taxes"] as ded,
>     salary * (1 - deductions["Federal Taxes"]) as salary_minus_fed_taxes
>   FROM employees) e
> WHERE round(e.salary_minus_fed_taxes) > 70000;
John Doe      100000.0  0.2    80000.0
Boss Man      200000.0  0.3    140000.0
Fred Finance  150000.0  0.3    105000.0
```

6.2.1 谓词操作符

表6-6描述了谓词操作符，这些操作符同样可以用于JOIN... ON 和 HAVING语句中。

表6-6 谓词操作符

操作符	支持的数据类型	描述
$A = B$	基本数据类型	如果A等于B则返回TRUE,反之返回FALSE
$A <= B$	基本数据类型	如果A和B都为NULL则返回TRUE, 其他的和等号 (=) 操作符的结果一致, 如果任一为NULL则结果为NULL (Hive 0.9.0版本新增)
$A == B$	没有	这个是错误的语法! SQL使用=, 而不是==
$A <> B, A != B$	基本数据类型	A或者B为NULL则返回NULL; 如果A不等于B则返回TRUE, 反之返回FALSE
$A < B$	基本数据类型	A或者B为NULL则返回NULL; 如果A小于B则返回TRUE, 反之返回FALSE
$A <= B$	基本数据类型	A或者B为NULL则返回NULL; 如果A小于或等于B则返回TRUE, 反之返回FALSE
$A > B$	基本数据类型	A或者B为NULL则返回NULL; 如果A大于B则返回TRUE, 反之返回FALSE
$A >= B$	基本数据类型	A或者B为NULL则返回NULL; 如果A大于或等于B则返回TRUE, 反之返回FALSE

操作符	支持的数据类型	描述
A [NOT] BETWEEN B AND C	基本数据类型	如果A, B或者C任一为NULL, 则结果为NULL。如果A的值大于或等于B而且小于或等于C, 则结果为TRUE, 反之为FALSE.如果使用NOT关键字则可达到相反的效果 (Hive 0.9.0版本中新增)
A IS NULL	所有数据类型	如果A等于NULL则返回TRUE;反之返回FALSE
A IS NOT NULL	所有数据类型	如果A不等于NULL则返回TRUE;反之返回FALSE
A [NOT] LIKE B	STRING类型	B是一个SQL下的简单正则表达式, 如果A与其匹配的话, 则返回TRUE;反之返回FALSE。B的表达式说明如下: 'x%'表示A必须以字母'x'开头, '%x'表示A必须以字母'x'结尾, 而'%x%'表示A包含有字母'x', 可以位于开头, 结尾或者字符串中间。类似地, 下划线'_'匹配单个字符。B必须要和整个字符串A相匹配才行.如果使用NOT关键字则可达到相反的效果
A RLIKE B, A REGEXP B	STRING类型	B是一个正则表达式, 如果A与其相匹配, 则返回TRUE';反之返回FALSE。匹配使用的是JDK中的正则表达式接口实现的, 因为正则规则也依据其中的规则。例如, 正则表达式必须和整个字符串A相匹配, 而不是只需与其子字符串匹配。关于正则表达式请参阅后面更多信息

后面我们将详细讨论下LIKE和RLIKE(请看第6.2.3节“LIKE和RLIKE”)。首先, 我们先说明下用户应该明白的关于浮点数比较的内容。

6.2.2 关于浮点数比较

浮点数比较的一个常见陷阱出现在不同类型间作比较的时候 (也就是FLOAT和DOUBLE比较)。思考下面这个对于员工表的查询语

句，该语句将返回员工姓名、工资和联邦税，过滤条件是薪水的减免税款超过0.2（20%）：

```
hive> SELECT name, salary, deductions['Federal Taxes']
> FROM employees WHERE deductions['Federal Taxes'] > 0.2;
John Doe      100000.0    0.2
Mary Smith     80000.0     0.2
Boss Man      200000.0    0.3
Fred Finance  150000.0    0.3
```

等一下！为什么`deductions['Federal Taxes'] = 0.2`的记录也被输出了？

这是个Hive的Bug吗？确实有个issue是关于这个问题的，但是其实际上反映了内部是如何进行浮点数比较的，这个问题几乎影响了在现在数字计算机中所有使用各种各样编程语言编写的软件（请参阅<https://issues.apache.org/jira/browse/HIVE-2586>）。

当用户写一个浮点数时，比如0.2，Hive会将该值保存为DOUBLE型的。我们之前定义`deductions`这个map的值的类型是FLOAT型的，这意味着Hive将隐式地将税收减免值转换为DOUBLE类型后再进行比较。这样应该是可以的，对吗？

事实上，这样行不通。这里解释下为什么不能。数字0.2不能够使用FLOAT或DOUBLE进行准确表示。（参阅http://docs.oracle.com/cd/E19957-01/806-3568/ncg_goldberg.html，深入探讨浮点数问题）。在这个例子中，0.2的最近似的精确值应略大于0.2，也就是0.2后面的若干个0后存在非零的数值。

为了简化一点，实际上我们可以说0.2对于FLOAT类型是0.2000001，而对于DOUBLE类型是0.20000000001。这是因为一个8个字节的DOUBLE值具有更多的小数位（也就是小数点后的位数）。当表中的FLOAT值通过Hive转换为DOUBLE值时，其产生的DOUBLE值是0.200000100000，这个值实际要比0.20000000001大。这就是为什么这个查询结果像是使用了`>=`而不是`>`了。

这个问题并非仅仅存在于Hive中或Java中（Hive是使用Java实现的）。而是所有使用IEEE标准进行浮点数编码的系统中存在的一个普遍的问题。

然而，Hive中有两种规避这个问题的方法。

首先，如果我们是从TEXTFILE文本文件(请参考第15章内容)中读取数据的话，也就是目前为止我们所假定使用的存储格式，那么Hive会从数据文件中读取字符串“0.2”，然后将其转换为一个真实的数字。我们可以在表模式中定义对应的字段类型为DOUBLE而不是FLOAT。这样我们就可以对deductions['Federal Taxes']这个DOUBLE值和0.2这个DOUBLE值进行比较。不过，这种变化会增加我们查询时所需的内存消耗。同时，如果存储格式是二进制文件格式（如SEQUENCEFILE（第15章将会进行讨论））的话，我们也不能简单地进行这样的改变。

第2个规避方案是显式地指出0.2为FLOAT类型的。Java中有一个很好的方式能够达到这个目的：只需要在数值末尾加上字母F或f(例如，0.2f)。不幸的是，Hive并不支持这种语法，这里我们必须使用cast操作符。

下面这个是修改后的查询语句，其将0.2类型转换为FLOAT类型了。通过这个修改，返回结果是符合预期的：

```
hive> SELECT name, salary, deductions['Federal Taxes'] FROM employees
> WHERE deductions['Federal Taxes'] > cast(0.2 AS FLOAT);
Boss Man      200000.0    0.3
Fred Finance  150000.0    0.3
```

注意cast操作符内部的语法：数值 AS FLOAT。

实际上，还有第3种解决方案，即：和钱相关的都避免使用浮点数。



警告

对浮点数进行比较时，需要保持极端谨慎的态度。要避免任何从窄类型隐式转换到更广泛类型的操作。

6.2.3 LIKE和RLIKE

表6-6描述了LIKE和RLIKE谓词操作符。用户可能在之前已经见过LIKE的使用了，因为其是一个标准的SQL操作符。其可以让我们通过字符串的开头或结尾，以及指定特定的子字符串，或当子字符串出现在字符串内的任何位置时进行匹配。

例如，下面3个查询依次分别选择了住址中街道是以字符串Ave结尾的雇员名称和住址、城市是以O开头的雇员名称和住址和街道名称中包含有Chicago的雇员名称和住址：

```
hive> SELECT name, address.street FROM employees WHERE address.street LIKE '%Ave.';  
John Doe 1 Michigan Ave.  
Todd Jones 200 Chicago Ave.  
  
hive> SELECT name, address.city FROM employees WHERE address.city LIKE '0%';  
Todd Jones Oak Park  
Bill King Obscuria  
hive> SELECT name, address.street FROM employees WHERE address.street LIKE '%Chi%';  
Todd Jones 200 Chicago Ave.
```

RLIKE子句是Hive中这个功能的一个扩展，其可以通过Java的正则表达式这个更强大的语言来指定匹配条件。不过本书中不会介绍正则表达式的语法和功能。表6-6中的RLIKE项有关于正则表达式更详细信息介绍的链接。这里，我们通过一个例子来展示它们的用法，这个例子会从employees表中查找所有住址的街道名称中含有单词Chicago或Ontario的雇员名称和街道信息：

```
hive> SELECT name, address.street  
> FROM employees WHERE address.street RLIKE '.*\b(Chicago|Ontario)\b.*';  
Mary Smith 100 Ontario St.  
Todd Jones 200 Chicago Ave.
```

关键字RLIKE后面的字符串表达如下含义：字符串中的点号(.) 表示和任意的字符匹配，星号(*) 表示重复“左边的字符串”（在以上所示2个例子中为点号）零次到无数次。表达式(x|y)表示和x或者y匹配。

不过，“Chicago”或者“Ontario”字符串前可能没有其他任何字符，而且它们后面也可能不含有其他任何字符。当然，我们也可以通过2个LIKE子句来改写这个例子为如下这个样子：

```
SELECT name, address FROM employees  
WHERE address.street LIKE '%Chicago%' OR address.street LIKE '%Ontario%';
```

通过正则表达式可以比如上这种通过多个LIKE子句进行过滤表达更丰富的匹配条件。

关于Hive中通过Java实现的正则表达式的更详细信息，请查看如下链接中关于Java的正则表达式语法部分的介绍：

<http://docs.oracle.com/javase/6/docs/api/java/util/regex/Pattern.html>，或者可以参考Tony Stubblebine (O'Reilly)所著的《正则表达式参考手册》以及Jan Goyvaerts 和 Steven Levithan (O'Reilly)所著的《正则表达式Cookbook》，也可以参考Jeffrey E.F. Friedl (O'Reilly)所著的《精通正则表达式-（第三版）》。

6.3 GROUP BY 语句

GROUP BY 语句通常会和聚合函数一起使用，按照一个或者多个列对结果进行分组，然后对每个组执行聚合操作。

我们重新看下第4.3.2节“外部表”中所介绍的股价交易表stocks。如下这个查询语句按照苹果公司股票（股票代码APPL）的年份对股票记录进行分组，然后计算每年的平均收盘价：

```
hive> SELECT year(ymd), avg(price_close) FROM stocks
> WHERE exchange = 'NASDAQ' AND symbol = 'AAPL'
> GROUP BY year(ymd);
1984    25.578625440597534
1985    20.193676221040867
1986    32.46102808021274
1987    53.88968399108163
1988    41.540079275138766
1989    41.65976212516664
1990    37.56268799823263
1991    52.49553383386182
1992    54.80338610251119
1993    41.02671956450572
1994    34.0813495847914
...
```

HAVING语句

HAVING子句允许用户通过一个简单的语法完成原本需要通过子查询才能对GROUP BY语句产生的分组进行条件过滤的任务。如下是对前面的查询语句增加一个HAVING语句来限制输出结果中年平均收盘价要大于\$50.0:

```
hive> SELECT year(ymd), avg(price_close) FROM stocks
> WHERE exchange = 'NASDAQ' AND symbol = 'AAPL'
> GROUP BY year(ymd)
> HAVING avg(price_close) > 50.0;
1987    53.88968399108163
1991    52.49553383386182
1992    54.80338610251119
1999    57.77071460844979
2000    71.74892876261757
2005    52.401745992993554
...
```

如果没使用HAVING子句，那么这个查询将需要使用一个嵌套SELECT子查询：

```
hive> SELECT s2.year, s2.avg FROM
> (SELECT year(ymd) AS year, avg(price_close) AS avg FROM stocks
> WHERE exchange = 'NASDAQ' AND symbol = 'AAPL'
> GROUP BY year(ymd)) s2
> WHERE s2.avg > 50.0;
1987    53.88968399108163
...
```

6.4 JOIN语句

Hive支持通常的SQL JOIN语句，但是只支持等值连接。

6.4.1 INNER JOIN

内连接（INNER JOIN）中，只有进行连接的两个表中都存在与连接标准相匹配的数据才会被保留下。例如，如下这个查询对苹果公司的股价（股票代码AAPL）和IBM公司的股价（股票代码IBM）进行比较。股票表stocks进行自连接，连接条件是ymd字段（也就是year-month-day）内容必须相等。我们也称ymd字段是这个查询语句中的连接关键字。

```
hive> SELECT a.ymd, a.price_close, b.price_close
> FROM stocks a JOIN stocks b ON a.ymd = b.ymd
> WHERE a.symbol = 'AAPL' AND b.symbol = 'IBM';
2010-01-04    214.01 132.45
2010-01-05    214.38 130.85
2010-01-06    210.97 130.0
2010-01-07    210.58 129.55
2010-01-08    211.98 130.85
2010-01-11    210.11 129.48
...
```

ON子句指定了两个表间数据进行连接的条件。WHERE子句限制了左边表是AAPL的记录，右边表是IBM的记录。同时用户可以看到这个查询中需要为两个表分别指定表别名。

众所周知，IBM要比Apple老得多。IBM也比Apple具有更久的股票交易记录。不过，既然这是一个内连接（INNER JOIN），IBM的1984年9月7日前的记录就会被过滤掉，也就是Apple股票交易日的第一天算起！

标准SQL是支持对连接关键词进行非等值连接的，例如下面这个显示Apple和IBM对比数据的例子，连接条件是Apple的股票交易日期要比IBM的股票交易日期早。这个将会返回很少数据（如例6-1所示）！

例6-1 Hive中不支持的查询语句

```
SELECT a.ymd, a.price_close, b.price_close
FROM stocks a JOIN stocks b
ON a.ymd <= b.ymd
WHERE a.symbol = 'AAPL' AND b.symbol = 'IBM';
```

这个语句在Hive中是非法的，主要原因是通过MapReduce很难实现这种类型的连接。不过因为Pig提供了一个交叉生产功能，所以在Pig中是可以实现这种连接的，尽管Pig的原生连接功能并不支持这种连接。

同时，Hive目前还不支持在ON子句中的谓词间使用OR。

通过下面的例子我们来看下非自连接操作。dividends表的数据同样来自于infochimps.org，正如在第4.3.2节中所介绍的：

```
CREATE EXTERNAL TABLE IF NOT EXISTS dividends (
  ymd      STRING,
  dividend  FLOAT
)
PARTITIONED BY (exchange STRING, symbol STRING)
ROW FORMAT DELIMITED FIELDS TERMINATED BY ',';
```

下面这个例子就是苹果公司的stocks表和dividends表按照字段ymd和字段symbol作为等值连接键的内连接（INNER JOIN）：

```
hive> SELECT s.ymd, s.symbol, s.price_close, d.dividend
>   FROM stocks s JOIN dividends d ON s.ymd = d.ymd AND s.symbol = d.symbol
> WHERE s.symbol = 'AAPL';
1987-05-11  AAPL    77.0    0.015
1987-08-10  AAPL    48.25   0.015
1987-11-17  AAPL    35.0    0.02
...
1995-02-13  AAPL    43.75   0.03
1995-05-26  AAPL    42.69   0.03
1995-08-16  AAPL    44.5    0.03
1995-11-21  AAPL    38.63   0.03
```

是的，几年前Apple公司支付过一次股息，而且近期刚刚宣布会再次支付股息！注意到因为我们使用了内连接，我们只看到每隔3个月的记录。通常支付股息的时间表会在宣布季度业绩报告时进行公布。

用户可以对多于2张表的多张表进行连接操作。下面我们来对Apple公司、IBM公司和GE公司并排进行比较：

```
hive> SELECT a.ymd, a.price_close, b.price_close , c.price_close
>   FROM stocks a JOIN stocks b ON a.ymd = b.ymd
>           JOIN stocks c ON a.ymd = c.ymd
> WHERE a.symbol = 'AAPL' AND b.symbol = 'IBM' AND c.symbol = 'GE';
2010-01-04  214.01  132.45  15.45
2010-01-05  214.38  130.85  15.53
2010-01-06  210.97  130.0   15.45
2010-01-07  210.58  129.55  16.25
2010-01-08  211.98  130.85  16.6
2010-01-11  210.11  129.48  16.76
...
```

大多数情况下，Hive会对每对JOIN连接对象启动一个MapReduce任务。本例中，会首先启动一个MapReduce job对表a和表b进行连接操作，然后会再启动一个MapReduce job将第一个MapReduce job的输出和表c进行连接操作。



提示

为什么不是表b和表c先进行连接操作呢？这是因为Hive总是按照从左到右的顺序执行的。

不过，这个例子实际上得益于一个优化，这个后面我们将进行讨论。

6.4.2 JOIN优化

在前面的那个例子中，每个ON子句中都使用到了a.ymd作为其中一个JOIN连接键。在这种情况下，Hive通过一个优化可以在同一个MapReduce job中连接3张表。同样，如果b.ymd也用于ON子句中的话，那么也会应用到这个优化。



提示

当对3个或者更多个表进行JOIN连接时，如果每个ON子句都使用相同的连接键的话，那么只会产生一个MapReduce job。

Hive同时假定查询中最后一个表是最大的那个表。在对每行记录进行连接操作时，它会尝试将其他表缓存起来，然后扫描最后那个表进行计算。因此，用户需要保证连续查询中的表的大小从左到右是依次增加的。

回想下之前对表stocks和表dividends进行的连接操作。我们错误地将最小的表dividends放在了最后面：

```
SELECT s.ymd, s.symbol, s.price_close, d.dividend
FROM stocks s JOIN dividends d ON s.ymd = d.ymd AND s.symbol = d.symbol
WHERE s.symbol = 'AAPL';
```

应该交换下表stocks和表dividends的位置，如下所示：

```
SELECT s.ymd, s.symbol, s.price_close, d.dividend
FROM dividends d JOIN stocks s ON s.ymd = d.ymd AND s.symbol = d.symbol
WHERE s.symbol = 'AAPL';
```

不过因为这个数据集并不大，所以并没有明显地看出和之前执行的性能的差别，但是对于大数据集，用户将会感知到这个优化。

幸运的是，用户并非总是要将最大的表放置在查询语句的最后面的。这是因为Hive还提供了一个“标记”机制来显式地告之查询优化器哪张表是大表，使用方式如下：

```
SELECT /*+STREAMTABLE (s) */s.ymd, s.symbol, s.price_close, d.dividend
FROM stocks s JOIN dividends d ON s.ymd = d.ymd AND s.symbol = d.symbol
WHERE s.symbol = 'AAPL';
```

现在Hive 将会尝试将表stocks作为驱动表，即使其在查询中不是位于最后面的。

还有另外一个类似的非常重要的优化叫做map-side JOIN, 用户可以参考第6.4.9节中的内容。

6.4.3 LEFT OUTER JOIN

左外连接通过关键字LEFT OUTER进行标识:

```
hive> SELECT s.ymd, s.symbol, s.price_close, d.dividend
> FROM stocks s LEFT OUTER JOIN dividends d ON s.ymd = d.ymd AND s.symbol =
d.symbol
> WHERE s.symbol = 'AAPL';
...
1987-05-01  AAPL    80.0    NULL
1987-05-04  AAPL    79.75   NULL
1987-05-05  AAPL    80.25   NULL
1987-05-06  AAPL    80.0    NULL
1987-05-07  AAPL    80.25   NULL
1987-05-08  AAPL    79.0    NULL
1987-05-11  AAPL    77.0    0.015
1987-05-12  AAPL    75.5    NULL
1987-05-13  AAPL    78.5    NULL
1987-05-14  AAPL    79.25   NULL
1987-05-15  AAPL    78.25   NULL
1987-05-18  AAPL    75.75   NULL
1987-05-19  AAPL    73.25   NULL
1987-05-20  AAPL    74.5    NULL
...
```

在这种JOIN连接操作中，JOIN操作符左边表中符合WHERE子句的所有记录将会被返回。JOIN操作符右边表中如果没有符合ON后面连接条件的记录时，那么从右边表指定选择的列的值将会是NULL。

因此，在这个结果集中，我们看到Apple公司的股票记录都返回了，而d.dividend字段的值通常是NULL，除了当天有支付股息的那条记录（也就是输出中的1987年5月11日那天的记录）。

6.4.4 OUTER JOIN

在我们讨论其他外连接之前，让我们来讨论一个用户应该明白的问题。

回想下，前面我们说过，通过在WHERE子句中增加分区过滤器可以加快查询速度。为了提高前面那个查询的执行速度，我们可以对两张表的exchange字段增加谓词限定：

```
hive> SELECT s.ymd, s.symbol, s.price_close, d.dividend
  > FROM stocks s LEFT OUTER JOIN dividends d ON s.ymd = d.ymd AND s.symbol =
d.symbol
  > WHERE s.symbol = 'AAPL'
  > AND s.exchange = 'NASDAQ' AND d.exchange = 'NASDAQ';
1987-05-11  AAPL    77.0    0.015
1987-08-10  AAPL    48.25   0.015
1987-11-17  AAPL    35.0    0.02
1988-02-12  AAPL    41.0    0.02
1988-05-16  AAPL    41.25   0.02
...
```

不过，这时我们发现输出结果改变了，虽然我们可能认为我们不过增加了一个优化！我们重新获得每年4条左右的股票交易记录，而且我们发现每年对应的股息值都是非NULL的。换句话说，这个效果和之前的内连接（INNER JOIN）是一样的！

在大多数的SQL实现中，这种现象实际上是比较常见的。之所以发生这种情况，是因为会先执行JOIN语句，然后再将结果通过WHERE语句进行过滤。在到达WHERE语句时，d.exchange字段中大多数值为NULL，因此这个“优化”实际上过滤掉了那些非股息支付日的所有记录。

一个直接有效的解决方式是：移除掉WHERE语句中对dividends表的过滤条件，也就是去除掉d.exchange=‘NASDAQ’这个限制条件。

```
hive> SELECT s.ymd, s.symbol, s.price_close, d.dividend
  > FROM stocks s LEFT OUTER JOIN dividends d ON s.ymd = d.ymd AND s.symbol =
d.symbol
  > WHERE s.symbol = 'AAPL' AND s.exchange = 'NASDAQ';
...
1987-05-07  AAPL    80.25   NULL
1987-05-08  AAPL    79.0    NULL
1987-05-11  AAPL    77.0    0.015
1987-05-12  AAPL    75.5    NULL
1987-05-13  AAPL    78.5    NULL
...
```

这种方式并非很令人满意。用户可能会想知道是否可以将 WHERE语句中的内容放置到ON语句里，至少知道分区过滤条件是否可以放置在ON语句中。对于外连接（OUTER JOIN）来说是不可以这样的，尽管Hive Wiki中的文章宣传其应该是可以工作的（参考链接：<https://cwiki.apache.org/confluence/display/Hive/LanguageManual+Joins>）。

```
hive> SELECT s.ymd, s.symbol, s.price_close, d.dividend
  > FROM stocks s LEFT OUTER JOIN dividends d
  > ON s.ymd = d.ymd AND s.symbol = d.symbol
  > AND s.symbol = 'AAPL' AND s.exchange = 'NASDAQ' AND d.exchange = 'NASDAQ';
...
1962-01-02  GE      74.75  NULL
1962-01-02  IBM     572.0   NULL
1962-01-03  GE      74.0    NULL
1962-01-03  IBM     577.0   NULL
1962-01-04  GE      73.12   NULL
1962-01-04  IBM     571.25  NULL
1962-01-05  GE      71.25   NULL
1962-01-05  IBM     560.0   NULL
...
```

对于外连接(OUTER JOIN)会忽略掉分区过滤条件。不过，对于内连接（INNER JOIN）使用这样的过滤谓词确实是起作用的！

幸运的是，有一个适用于所有种类连接的解决方案，那就是使用嵌套SELECT语句：

```
hive> SELECT s.ymd, s.symbol, s.price_close, d.dividend FROM
  > (SELECT * FROM stocks WHERE symbol = 'AAPL' AND exchange = 'NASDAQ') s
  > LEFT OUTER JOIN
  > (SELECT * FROM dividends WHERE symbol = 'AAPL' AND exchange = 'NASDAQ') d
  > ON s.ymd = d.ymd;
...
1988-02-10  AAPL    41.0    NULL
1988-02-11  AAPL    40.63   NULL
1988-02-12  AAPL    41.0    0.02
1988-02-16  AAPL    41.25   NULL
1988-02-17  AAPL    41.88   NULL
...
```

嵌套SELECT语句会按照要求执行“下推”过程，在数据进行连接操作之前会先进行分区过滤。



提示

WHERE语句在连接操作执行后才会执行，因此WHERE语句应该只用于过滤那些非NULL值的列值。同时，和Hive的文档说明中相反的是，ON语句中的分区过滤条件外连接(OUTER JOIN)中是无效的，不过在内连接 (INNER JOIN) 中是有效的。

6.4.5 RIGHT OUTER JOIN

右外连接 (RIGHT OUTER JOIN) 会返回右边表所有符合 WHERE语句的记录。左表中匹配不上的字段值用NULL代替。

这里我们调整下stocks表和dividends表的位置来执行右外连接，并保留SELECT语句不变：

```
hive> SELECT s.ymd, s.symbol, s.price_close, d.dividend
> FROM dividends d RIGHT OUTER JOIN stocks s ON d.ymd = s.ymd AND d.symbol =
s.symbol
> WHERE s.symbol = 'AAPL';
...
1987-05-07    AAPL    80.25    NULL
1987-05-08    AAPL    79.0     NULL
1987-05-11    AAPL    77.0     0.015
1987-05-12    AAPL    75.5     NULL
1987-05-13    AAPL    78.5     NULL
...
```

6.4.6 FULL OUTER JOIN

最后介绍的完全外连接 (FULL OUTER JOIN) 将会返回所有表中符合WHERE语句条件的所有记录。如果任一表的指定字段没有符合条件的值的话，那么就使用NULL值替代。

如果我们将前面的查询改写成一个完全外连接查询的话，事实上获得的结果和之前的一样。这是因为不可能存在有股息支付记录而没有对应的股票交易记录的情况。

```
hive> SELECT s.ymd, s.symbol, s.price_close, d.dividend
> FROM dividends d FULL OUTER JOIN stocks s ON d.ymd = s.ymd AND d.symbol =
s.symbol
> WHERE s.symbol = 'AAPL';
```

```
...
1987-05-07    AAPL    80.25    NULL
1987-05-08    AAPL    79.0     NULL
1987-05-11    AAPL    77.0     0.015
1987-05-12    AAPL    75.5     NULL
1987-05-13    AAPL    78.5     NULL
...
```

6.4.7 LEFT SEMI-JOIN

左半开连接（LEFT SEMI-JOIN）会返回左边表的记录，前提是其记录对于右边表满足ON语句中的判定条件。对于常见的内连接（INNER JOIN）来说，这是一个特殊的、优化了的情况。大多数的SQL方言会通过IN ... EXISTS结构来处理这种情况。例如下面的例 6-2 中所示的查询，其将试图返回限定的股息支付日内的股票交易记录，不过这个查询Hive是不支持的。

例6-2 Hive中不支持的查询

```
SELECT s.ymd, s.symbol, s.price_close FROM stocks s
WHERE s.ymd, s.symbol IN
(SELECT d.ymd, d.symbol FROM dividends d);
```

不过，用户可以使用如下的LEFT SEMI JOIN语法达到同样的目的：

```
hive> SELECT s.ymd, s.symbol, s.price_close
>   FROM stocks s LEFT SEMI JOIN dividends d ON s.ymd = d.ymd AND s.symbol =
d.symbol;
...
1962-11-05    IBM    361.5
1962-08-07    IBM    373.25
1962-05-08    IBM    459.5
1962-02-06    IBM    551.5
```

请注意，SELECT和WHERE语句中不能引用到右边表中的字段。



警告

Hive不支持右半开连接（RIGHT SEMI-JOIN）。

SEMI-JOIN比通常的INNER JOIN要更高效，原因如下：对于左表中一条指定的记录，在右边表中一旦找到匹配的记录，Hive就会立即

停止扫描。从这点来看，左边表中选择的列是可以预测的。

6.4.8 笛卡尔积JOIN

笛卡尔积是一种连接，表示左边表的行数乘以右边表的行数等于笛卡尔结果集的大小。也就是说如果左边表有5行数据，而右边表有6行数据，那么产生的结果将是30行数据：

```
SELECTS * FROM stocks JOIN dividends;
```

如上面的查询，以stocks表和dividends表为例，实际上很难找到合适的理由来执行这类连接，因为一只股票的股息通常并非和另一只股票配对。此外，笛卡尔积会产生大量的数据。和其他连接类型不同，笛卡尔积不是并行执行的，而且使用MapReduce计算架构的话，任何方式都无法进行优化。

这里非常有必要指出，如果使用了错误的连接（JOIN）语法可能会导致产生一个执行时间长、运行缓慢的笛卡尔积查询。例如，如下这个查询在很多数据库中会被优化成内连接（INNER JOIN），但是在Hive中没有此优化：

```
hive > SELECT * FROM stocks JOIN dividends  
> WHERE stock.symbol = dividends.symbol and stock.symbol='AAPL';
```

在Hive中，这个查询在应用WHERE语句中的谓词条件前会先进行完全笛卡尔积计算。这个过程将会消耗很长的时间。如果设置属性hive.mapred.mode值为strict的话，Hive会阻止用户执行笛卡尔积查询。第10章“调整”中我们将更详尽地讨论这个功能。



提示

笛卡尔积在一些情况下是很有用的。例如，假设有一个表表示用户偏好，另有一个表表示新闻文章，同时有一个算法会推测出用户可能会喜欢读哪些文章。这个时候就需要使用笛卡尔积生成所有用户和所有网页的对应关系的集合。

6.4.9 map-side JOIN

如果所有表中只有一张表是小表，那么可以在最大的表通过mapper的时候将小表完全放到内存中。Hive可以在map端执行连接过程（称为map-side JOIN），这是因为Hive可以和内存中的小表进行逐一匹配，从而省略掉常规连接操作所需要的reduce过程。即使对于很小的数据集，这个优化也明显地要快于常规的连接操作。其不仅减少了reduce过程，而且有时还可以同时减少map过程的执行步骤。

stocks表和dividends表之间的连接操作也可以利用到这个优化，因为dividends表中的数据集很小，已经可以全部放在内存中缓存起来了。

在Hive v0.7之前的版本中，如果想使用这个优化，需要在查询语句中增加一个标记来进行触发。如下面的这个内连接（INNER JOIN）的例子所示：

```
SELECT /*+ MAPJOIN(d) */ s.ymd, s.symbol, s.price_close, d.dividend
FROM stocks s JOIN dividends d ON s.ymd = d.ymd AND s.symbol = d.symbol
WHERE s.symbol = 'AAPL';
```

在一个比较快的MacBook Pro笔记本电脑上执行上面这个优化后的查询大约需要23s，这明显比优化前执行所消耗的33s要快。在相同的股票样本数据集上执行，执行速度提高了大约30%。

从Hive v0.7版本开始，废弃了这种标记的方式，不过如果增加了这个标记同样是有 效的。如果不加上这个标记，那么这时用户需要设置属性hive.auto.convert JOIN的值 为true，这样Hive才会在必要的时候启动这个优化。默认情况下这个属性的值是false。

```
hive> set hive.auto.convert.join=true;
hive> SELECT s.ymd, s.symbol, s.price_close, d.dividend
> FROM stocks s JOIN dividends d ON s.ymd = d.ymd AND s.symbol = d.symbol
> WHERE s.symbol = 'AAPL';
```

需要注意的是，用户也可以配置能够使用这个优化的小表的大小。如下是这个属性的默认值（单位是字节）：

```
hive.mapjoin.smalltable.filesize=25000000
```

如果用户期望Hive在必要的时候自动启动这个优化的话，那么可以将这一个（或两个）属性设置在\$HOME/.hiverc文件中。

Hive对于右外连接（RIGHT OUTER JOIN）和全外连接（FULL OUTER JOIN）不支持这个优化。

如果所有表中的数据是分桶的，那么对于大表，在特定的情况下同样可以使用这个优化，详细介绍请参见第9.6节“分桶表数据存储”中的介绍。简单地说，表中的数据必须是按照ON语句中的键进行分桶的，而且其中一张表的分桶的个数必须是另一张表分桶个数的若干倍。当满足这些条件时，那么Hive可以在map阶段按照分桶数据进行连接。因此这种情况下，不需要先获取到表中所有的内容，之后才去和另一张表中每个分桶进行匹配连接。

不过，这个优化同样默认是没有开启的。需要设置参数hive.optimize.bucketmapJOIN为true才可以开启此优化：

```
set hive.optimize.bucketmapJOIN=true;
```

如果所涉及的分桶表都具有相同的分桶数，而且数据是按照连接键或桶的键进行排序的，那么这时Hive可以执行一个更快的分类-合并连接（sort-merge JOIN）。同样地，这个优化需要设置如下属性才能开启：

```
set hive.input.format=org.apache.hadoop.hive.ql.io.BucketizedHiveInputFormat;
set hive.optimize.bucketmapjoin=true;
set hive.optimize.bucketmapjoin.sortedmerge=true;
```

6.5 ORDER BY和SORT BY

Hive中ORDER BY语句和其他的SQL方言中的定义是一样的。其会对查询结果集执行一个全局排序。这也就是说会有一个所有的数据都通过一个reducer进行处理的过程。对于大数据集，这个过程可能会消耗太过漫长的时间来执行。

Hive增加了一个可供选择的方式，也就是SORT BY，其只会在每个reducer中对数据进行排序，也就是执行一个局部排序过程。这可以

保证每个reducer的输出数据都是有序的（但并非全局有序）。这样可以提高后面进行的全局排序的效率。

对于这两种情况，语法区别仅仅是，一个关键字是ORDER，另一个关键字是SORT。用户可以指定任意期望进行排序的字段，并可以在字段后面加上ASC关键字（默认的），表示按升序排序，或加DESC关键字，表示按降序排序。

下面是一个使用ORDER BY的例子：

```
SELECT s.ymd, s.symbol, s.price_close
FROM stocks s
ORDER BY s.ymd ASC, s.symbol DESC;
```

下面是一个类似的例子，不过使用的是SORT BY：

```
SELECT s.ymd, s.symbol, s.price_close
FROM stocks s
SORT BY s.ymd ASC, s.symbol DESC;
```

上面介绍的两个查询看上去几乎一样，不过如果使用的reducer的个数大于1的话，那么输出结果的排序就大不一样了。既然只保证每个reducer的输出是局部有序的，那么不同reducer的输出就可能会有重叠的。

因为ORDER BY操作可能会导致运行时间过长，如果属性hive.mapred.mode的值是strict的话，那么Hive要求这样的语句必须加有LIMIT语句进行限制。默认情况下，这个属性的值是nonstrict，也就是不会有这样的限制。

6.6 含有SORT BY 的DISTRIBUTE BY

DISTRIBUTE BY控制map的输出在reducer中是如何划分的。MapReduce job中传输的所有数据都是按照键-值对的方式进行组织的，因此Hive在将用户的查询语句转换成MapReduce job时，其必须在内部使用这个功能。

通常，用户不需要担心这个特性。不过对于使用了Streaming特性（请参考第14章内容）以及一些状态为UDAF（用户自定义聚合函

数, 参见第13.4节“聚合函数”中的介绍) 的查询是个例外。还有, 在另外一个场景下, 使用这些语句是有用的。

默认情况下, MapReduce计算框架会依据map输入的键计算相应的哈希值, 然后按照得到的哈希值将键-值对均匀分发到多个reducer中去。不过不幸的是, 这也就意味着当我们使用**SORT BY**时, 不同reducer的输出内容会有明显的重叠, 至少对于排列顺序而言是这样, 即使每个reducer的输出的数据都是有序的。

假设我们希望具有相同股票交易码的数据在一起处理。那么我们可以使用**DISTRIBUTE BY**来保证具有相同股票交易码的记录会分发到同一个reducer中进行处理, 然后使用**SORT BY**来按照我们的期望对数据进行排序。如下这个例子就演示了这种用法:

```
hive> SELECT s.ymd, s.symbol, s.price_close
  > FROM stocks s
  > DISTRIBUTE BY s.symbol
  > SORT BY s.symbol ASC, s.ymd ASC;
1984-09-07 AAPL 26.5
1984-09-10 AAPL 26.37
1984-09-11 AAPL 26.87
1984-09-12 AAPL 26.12
1984-09-13 AAPL 27.5
1984-09-14 AAPL 27.87
1984-09-17 AAPL 28.62
1984-09-18 AAPL 27.62
1984-09-19 AAPL 27.0
1984-09-20 AAPL 27.12
...
```

当然, 上面例子中的**ASC**关键字是可以省略掉的, 因为其就是缺省值。这里加上了**ASC**关键字的原因, 稍后我们将会进行简要的阐述。

DISTRIBUTE BY和**GROUP BY**在其控制着reducer是如何接受一行行数据进行处理这方面是类似的, 而**SORT BY**则控制着reducer内的数据是如何进行排序的。

需要注意的是, Hive要求**DISTRIBUTE BY**语句要写在**DORT BY**语句之前。

6.7 CLUSTER BY

在前面的例子中，`s.symbol`列被用在了`DISTRIBUTE BY`语句中，而`s.symbol`列和`s.ymd`位于`SORT BY`语句中。如果这2个语句中涉及到的列完全相同，而且采用的是升序排序方式（也就是默认的排序方式），那么在这种情况下，`CLUSTER BY`就等价于前面的2个语句，相当于是前面2个句子的一个简写方式。

如下面的例子所示，我们将前面的查询语句中`SORT BY`后面的`s.ymd`字段去掉而只对`s.symbol`字段使用`CLUSTER BY`语句：

```
hive> SELECT s.ymd, s.symbol, s.price_close
>   FROM stocks s
>  CLUSTER BY s.symbol;
2010-02-08 AAPL 194.12
2010-02-05 AAPL 195.46
2010-02-04 AAPL 192.05
2010-02-03 AAPL 199.23
2010-02-02 AAPL 195.86
2010-02-01 AAPL 194.73
2010-01-29 AAPL 192.06
2010-01-28 AAPL 199.29
2010-01-27 AAPL 207.88
...
```

因此排序限制中去除掉了`s.ymd`字段，所以输出中展示的是股票数据的原始排序方式，也就是降序排列。

使用`DISTRIBUTE BY ... SORT BY`语句或其简化版的`CLUSTER BY`语句会剥夺`SORT BY`的并行性，然而这样可以实现输出文件的数据是全局排序的。

6.8 类型转换

在第3.1节“基本数据类型”中我们简要提及了Hive会在适当的时候，对数值型数据类型进行隐式类型转换，其关键字是`cast`。例如，对不同类型的2个数值进行比较操作时就会有这种隐式类型转换。关于这话题我们在第6.2.1节“谓词操作符”和第6.2.2节“关于浮点数比较”中已经进行了比较全面的讨论。

这里我们讨论下`cast()`函数，用户可以使用这个函数对指定的值进行显式的类型转换。

回想一下，前面我们介绍过的employees表中salary列是使用FLOAT数据类型的。现在，我们假设这个字段使用的数据类型是STRING的话，那么我们如何才能将其作为FLOAT值进行计算呢？

如下这个例子会先将值转换为FLOAT类型，然后才会执行数值大小比较过程：

```
SELECT name, salary FROM employees
WHERE cast(salary AS FLOAT) < 100000.0;
```

类型转换函数的语法是`cast(value AS TYPE)`。如果例子中的salary字段的值不是合法的浮点数字符串的话，那么结果会怎么样呢？这种情况下，Hive会返回NULL。

需要注意的是，将浮点数转换成整数的推荐方式是使用表6-2中列举的`round()`或者`floor()`函数，而不是使用类型转换操作符`cast`。

类型转换BINARY值

Hive v0.8.0版本中新引入的BINARY类型只支持将BINARY类型转换为STRING类型。不过，如果用户知道其值是数值的话，那么可以通过嵌套`cast()`的方式对其进行类型转换，如下面例子所示，其中b字段类型是BINARY：

```
SELECT (2.0*cast(cast(b as string) as double)) from src;
```

用户同样可以将STRING类型转换为BINARY类型。

6.9 抽样查询

对于非常大的数据集，有时用户需要使用的是一个具有代表性的查询结果而不是全部结果。Hive可以通过对表进行分桶抽样来满足这个需求。

在下面这个例子中，假设numbers表只有number字段，其值是1到10。

我们可以使用rand()函数进行抽样，这个函数会返回一个随机值。前两个查询都返回了两个不相等的值，而第3个查询语句无返回结果：

```
hive> SELECT * from numbers TABLESAMPLE(BUCKET 3 OUT OF 10 ON rand()) s;
2
4

hive> SELECT * from numbers TABLESAMPLE(BUCKET 3 OUT OF 10 ON rand()) s;
7
10

hive> SELECT * from numbers TABLESAMPLE(BUCKET 3 OUT OF 10 ON rand()) s;
```

如果我们是按照指定的列而非rand()函数进行分桶的话，那么同一语句多次执行的返回值是相同的：

```
hive> SELECT * from numbers TABLESAMPLE(BUCKET 3 OUT OF 10 ON number) s;
2

hive> SELECT * from numbers TABLESAMPLE(BUCKET 5 OUT OF 10 ON number) s;
4

hive> SELECT * from numbers TABLESAMPLE(BUCKET 3 OUT OF 10 ON number) s;
2
```

分桶语句中的分母表示的是数据将会被散列的桶的个数，而分子表示将会选择的桶的个数：

```
hive> SELECT * from numbers TABLESAMPLE(BUCKET 1 OUT OF 2 ON number) s;
2
4
6
8
10

hive> SELECT * from numbers TABLESAMPLE(BUCKET 2 OUT OF 2 ON number) s;
1
3
5
7
9
```

6.9.1 数据块抽样

Hive提供了另外一种按照抽样百分比进行抽样的方式，这种是基于行数的，按照输入路径下的数据块百分比进行的抽样：

```
hive> SELECT * FROM numbersflat TABLESAMPLE(0.1 PERCENT) s;
```



提示

这种抽样方式不一定适用于所有的文件格式。另外，这种抽样的最小抽样单元是一个HDFS数据块。因此，如果表的数据大大小于普通的块大小128MB的话，那么将会返回所有行。

基于百分比的抽样方式提供了一个变量，用于控制基于数据块的调优的种子信息：

```
<property>
  <name>hive.sample.seednumber</name>
  <value>0</value>
  <description>A number used for percentage sampling. By changing this
  number, user will change the subsets of data sampled.</description>
</property>
```

6.9.2 分桶表的输入裁剪

从第一次看TABLESAMPLE语句，精明的用户可能会得出“如下的查询和TABLESAMPLE操作相同”的结论：

```
hive> SELECT * FROM numbersflat WHERE number % 2 = 0;
2
4
6
8
10
```

对于大多数类型的表确实是这样的。抽样会扫描表中所有的数据，然后在每N行中抽取一行数据。不过，如果TABLESAMPLE语句中指定的列和CLUSTERED BY语句中指定的列相同，那么TABLESAMPLE查询就只会扫描涉及到的表的哈斯分区下的数据：

```
hive> CREATE TABLE numbers_bucketed (number int) CLUSTERED BY (number) INTO 3
BUCKETS;

hive> SET hive.enforce.bucketing=true;

hive> INSERT OVERWRITE TABLE numbers_bucketed SELECT number FROM numbers;

hive> dfs -ls /user/hive/warehouse/mydb.db/numbers_bucketed;
/usr/hive/warehouse/mydb.db/numbers_bucketed/000000_0
/usr/hive/warehouse/mydb.db/numbers_bucketed/000001_0
/usr/hive/warehouse/mydb.db/numbers_bucketed/000002_0
```

```
hive> dfs -cat /user/hive/warehouse/mydb.db/numbers_bucketed/000001_0;
1
7
10
4
```

因为这个表已经聚集成3个数据桶了，下面的这个查询可以高效地仅对其中一个数据桶进行抽样：

```
hive> SELECT * FROM numbers_bucketed TABLESAMPLE (BUCKET 2 OUT OF 3 ON NUMBER) s;
1
7
10
4
```

6.10 UNION ALL

UNION ALL可以将2个或多个表进行合并。每一个union子查询都必需具有相同的列，而且对应的每个字段的字段类型必须是一致的。例如，如果第2个字段是FLOAT类型的，那么所有其他子查询的第2个字段必须都是FLOAT类型的。

下面是个将日志数据进行合并的例子：

```
SELECT log.ymd, log.level, log.message
  FROM (
    SELECT l1.ymd, l1.level,
      l1.message, 'Log1' AS source
    FROM log1 l1
  UNION ALL
    SELECT l2.ymd, l2.level,
      l2.message, 'Log2' AS source
    FROM log1 l2
  ) log
 SORT BY log.ymd ASC;
```

UNION也可用于同一个源表的数据合并。从逻辑上讲，可以使用一个SELECT和WHERE语句来获得相同的结果。这个技术便于将一个长的复杂的WHERE语句分割成2个或多个UNION子查询。不过，除非源表建立了索引，否则，这个查询将会对同一份源数据进行多次拷贝分发。例如：

```
FROM (
  FROM src SELECT src.key, src.value WHERE src.key < 100
  UNION ALL
```

```
| FROM src SELECT src.* WHERE src.key > 110
| ) unioninput
| INSERT OVERWRITE DIRECTORY '/tmp/union.out' SELECT unioninput.*
```

[1]在撰写本文时，Hive Wiki中展示了一个不正确的语法来通过正则表达式指定列。

第7章 HiveQL: 视图

视图可以允许保存一个查询并像对待表一样对这个查询进行操作。这是一个逻辑结构，因为它不像一个表会存储数据。换句话说，Hive目前暂不支持物化视图。

当一个查询引用一个视图时，这个视图所定义的查询语句将和用户的查询语句组合在一起，然后供Hive制定查询计划。从逻辑上讲，可以想象为Hive先执行这个视图，然后使用这个结果进行余下后续的查询。

7.1 使用视图来降低查询复杂度

当查询变得长或复杂的时候，通过使用视图将这个查询语句分割成多个小的、更可控的片段可以降低这种复杂度。这点和在编程语言中使用函数或者软件设计中的分层设计的概念是一致的。封装复杂的部分可以是最终用户通过重用重复的部分来构建复杂的查询。例如，如下是一个具有嵌套子查询的查询：

```
FROM (
  SELECT * FROM people JOIN cart
  ON (cart.people_id=people.id) WHERE firstname='john'
) a SELECT a.lastname WHERE a.id=3;
```

Hive查询语句中含有多层嵌套是非常常见的。在下面这个例子中，嵌套子查询变成了一个视图：

```
CREATE VIEW shorter_join AS
SELECT * FROM people JOIN cart
ON (cart.people_id=people.id) WHERE firstname='john';
```

现在就可以像操作表一样来操作这个视图了。本次的查询语句中我们为SELECT语句增加了一个WHERE子句，这样就大大简化了之前的那个查询语句：

```
SELECT lastname FROM shorter_join WHERE id=3;
```

7.2 使用视图来限制基于条件过滤的数据

对于视图来说一个常见的使用场景就是基于一个或多个列的值来限制输出结果。有些数据库允许将视图作为一个安全机制，也就是不给用户直接访问具有敏感数据的原始表，而是提供给用户一个通过 WHERE子句限制了的视图，以供访问。Hive目前并不支持这个功能，因为用户必须具有能够访问整个底层原始表的权限，这时视图才能工作。然而，通过创建视图来限制数据访问可以用来保护信息不被随意查询：

```
hive> CREATE TABLE userinfo (
>   firstname string, lastname string, ssn string, password string);
hive> CREATE VIEW safer_user_info AS
>   SELECT firstname, lastname FROM userinfo;
```

如下是通过WHERE子句限制数据访问的视图的另一个例子。在这种情况下，我们希望提供一个员工表视图，只暴露来自特定部门的员工信息：

```
hive> CREATE TABLE employee (firstname string, lastname string,
>   ssn string, password string, department string);
hive> CREATE VIEW techops_employee AS
>   SELECT firstname, lastname, ssn FROM userinfo WHERE department='techops';
```

7.3 动态分区中的视图和map类型

记得在第3章我们就介绍过Hive支持array、map和struct数据类型。这些数据类型在传统数据库中并不常见，因为它们破坏了第一范式。Hive可将一行文本作为一个map而非一组固定的列的能力，加上视图功能，就允许用户可以基于同一个物理表构建多个逻辑表。

思考下面这个示例文件。其将整行作为一个map处理，而不是一列固定的列。这里没有使用Hive的默认分隔符，这个文件使用^A(Control + A)作为集合内元素间的分隔符（例如，本例中map的多个键-值对之间的分隔符），然后使用^B (Control + B) 作为map中的键和值之间的分隔符。因为这条记录较长，所以为了更清晰地表达，我们人为地增加了空行：

```
time^B1298598398404^Atype^Brequest^Astate^Bny^Acity^Bwhite
plains^Apar^Bmuffler
```

```
time^B1298598398432^Atype^Bresponse^Astate^Bny^Acity^Btarrytown^
Apart\^Bmuffler

time^B1298598399404^Atype^Brequest^Astate^Btx^Acity^Baustin^
Apart^Bheadlight
```

下面我们来创建表:

```
CREATE EXTERNAL TABLE dynamictable(cols map<string, string>)
ROW FORMAT DELIMITED
FIELDS TERMINATED BY '\004'
COLLECTION ITEMS TERMINATED BY '\001'
MAP KEYS TERMINATED BY '\002'
STORED AS TEXTFILE;
```

上面的例子中，因为每行只有一个字段，因此FIELDS TERMINATED BY语句所指定的分隔符实际上没有任何影响。

现在我们可以创建这样一个视图，其仅取出type值等于request的city、state和part 3个字段，并将视图命名为orders。视图orders具有3个字段：state、city和part。

```
CREATE VIEW orders(state, city, part) AS
SELECT cols["state"], cols["city"], cols["part"]
FROM dynamictable
WHERE cols["type"] = "request";
```

我们创建的第2个视图名为shipments。这个视图返回time和part 2个字段作为列，限制条件是type的值为response:

```
CREATE VIEW shipments(time, part) AS
SELECT cols["time"], cols["parts"]
FROM dynamictable
WHERE cols["type"] = "response";
```

关于这个特性的另一个例子，请查看下如下链接：
<http://dev.bizo.com/2011/02/columns-in-hive.html#!/2011/02/columns-in-hive.html>。

7.4 视图零零碎碎相关的事情

我们说过，Hive会先解析视图，然后使用解析结果再来解析整个查询语句。然而，作为Hive查询优化器的一部分，查询语句和视图语

句可能会合并成一个单一的实际查询语句。

然而，这个概念视图仍然适用于视图和使用这个视图的查询语句都包含了一个**ORDER BY**子句或一个**LIMIT**子句的情况。这时会在使用这个视图的查询语句之前对该视图进行解析。

例如，如果视图语句含有一个**LIMIT 100**子句，而同时使用到这个视图的查询含有一个**LIMIT 200**子句，那么用户最终最多只能获取100条结果记录。

因为定义一个视图实际上并不会“具体化”操作任何实际数据，所以视图实际上是对其所使用到的表和列的一个查询语句固化过程。因此，如果视图所涉及的表或者列不再存在时，会导致视图查询失败。

创建视图时用户还可以使用其他一些子句。如下例子修改了我们前面那个例子：

```
CREATE VIEW IF NOT EXISTS shipments(time, part)
COMMENT 'Time and parts for shipments.'
TBLPROPERTIES ('creator' = 'me')
AS SELECT ...;
```

对于表来说，**IF NOT EXISTS**和**COMMENT...**子句是可选的，而且和表创建语句具有相同的含义。

一个视图的名称要和这个视图所在的数据库下的其他所有表和视图的名称不同。

用户还可以为所有的新列或部分新列增加一个**COMMENT**子句，进行写注释。这些注释并非“继承”原始表中的定义。

同样地，如果**AS SELECT**子句中包含没有命名别名的表达式的话，例如**size(cols)**(计算**cols**中元素的个数)，那么Hive将会使用_**N**作为新的列名，其中**N**表示从0开始的一个整数。如果**AS SELECT**语句不合法的话，那么创建视图过程将失败。

在**AS SELECT**子句之前，用户可以通过定义**TBLPROPERTIES**来定义表属性信息，这点和表相同。上例中，我们定义的属性为“**creator**”，表示这个视图的创建者名称。

第4.3节“创建表”中讨论过的CREATE TABLE ... LIKE ...结构同样适用于复制视图，只需要在LIKE表达式里面写视图名就可以了：

```
CREATE TABLE shipments2
LIKE shipments;
```

用户也可以像以前一样选择性使用EXTERNAL关键字和LOCATION...子句。



警告

对于Hive v0.8.0版本和这个版本前的其他版本来说，这个语句的行为是不同的。对于v0.8.0版本，这个命令会创建一个新的表，而不是一个新的视图，同时使用默认的SerDe方式和文件格式。而对于之前的早期版本来说，会创建一个新的视图。

删除视图的方式和删除表的方式类似：

```
DROP VIEW IF EXISTS shipments;
```

和往常一样，上面例子中的IF EXISTS语句是可选的。

通过SHOW TABLES语句（没有SHOW VIEWS这样的语句）同样可以查看到视图，但是不能使用DROP TABLE语句来删除视图。

和表一样，DESCRIBE和DESCRIBE EXTENDED语句可以显示视图的元数据信息。如果使用后面那个命令，输出信息中的“Detailed Table Information”部分会有一个tableType字段，字段值显示的是“VIRTUAL_VIEW”。

视图不能够作为INSERT语句或LOAD命令的目标表。

最后要说明的是，视图是只读的。对于视图只允许改变元数据中TBLPROPERTIES属性信息：

```
ALTER VIEW shipments SET TBLPROPERTIES ('created_at' = 'some_timestamp');
```

第8章 HiveQL: 索引

Hive只有有限的索引功能。Hive中没有普通关系型数据库中键的概念，但是还是可以对一些字段建立索引来加速某些操作的。一张表的索引数据存储在另外一张表中。

同时，因为这是一个相对比较新的功能，所以目前还没有提供很多的选择。然而，索引处理模块被设计成为可以定制的Java编码的插件，因此，用户可以根据需要对其进行实现，以满足自身的需求。

当逻辑分区实际上太多太细而几乎无法使用时，建立索引也就成为分区的另一个选择。建立索引可以帮助裁剪掉一张表的一些数据块，这样能够减少MapReduce的输入数据量。并非所有的查询都可以通过建立索引获得好处。通过EXPLAIN命令可以查看某个查询语句是否用到了索引。

Hive中的索引和那些关系型数据库中的一样，需要进行仔细评估才能使用。维护索引也需要额外的存储空间，同时创建索引也需要消耗计算资源。用户需要在建立索引为查询带来的好处和因此而需要付出的代价之间做出权衡。

8.1 创建索引

现在我们来为我们在第56页“分区表、管理表”章节讲述过的管理分区表中的employees表建立一个索引。下面这段是我们之前的表定义语句，作为参照：

```
CREATE TABLE employees (
  name          STRING,
  salary        FLOAT,
  subordinates ARRAY<STRING>,
  deductions   MAP<STRING, FLOAT>,
  address       STRUCT<street:STRING, city:STRING, state:STRING, zip:INT>
)
PARTITIONED BY (country STRING, state STRING);
```

下面我们仅对分区字段country建立索引：

```
CREATE INDEX employees_index
ON TABLE employees (country)
AS 'org.apache.hadoop.hive.ql.index.compact.CompactIndexHandler'
WITH DEFERRED REBUILD
IDXPROPERTIES ('creator = 'me', 'created_at' = 'some_time')
IN TABLE employees_index_table
PARTITIONED BY (country, name)
COMMENT 'Employees indexed by country and name.';
```

在这种情况下，我们没有像原表那样对索引表进行同一粒度的分区划分。其实我们是可以那么做的。如果我们完全省略掉 PARTITIONED BY 语句的话，那么索引将会包含原始表的所有分区。

AS ...语句指定了索引处理器，也就是一个实现了索引接口的Java类。Hive本身包含了一些典型的索引实现。这里所展示的 CompactIndexHandler就是其中的一个实现。可以通过第三方的实现来最优化地处理特定的场景，支持特定的文件格式，等等。在第121页的“实现一个定制化的索引处理器”章节，我们将对如何实现一个用户定制的索引处理器进行详细的说明。

下一节我们将讨论WITH DEFERRED REBUILD这个子句的含义。

并非一定要求索引处理器在一张新表中保留索引数据，但是如果需要的话，会使用到IN TABLE ...子句。这个句式提供了和创建其他类型表一样的很多功能。特别地，例子中没有使用到ROW FORMAT、STORED AS、STORED BY、LOCATION等我们在第4章所讨论过的选项。这些其实都是可以在最后的COMMENT语句前增加的。

目前，除了S3中的数据，对外部表和视图都是可以建立索引的。

Bitmap索引

Hive v0.8.0版本中新增了一个内置bitmap索引处理器。bitmap索引普遍应用于排重后值较少的列。下面是对前面的例子使用bitmap索引处理器重写后的语句：

```
CREATE INDEX employees_index
ON TABLE employees (country)
AS 'BITMAP'
WITH DEFERRED REBUILD
```

```
IDXPROPERTIES ('creator' = 'me', 'created_at' = 'some_time')
IN TABLE employees_index_table
PARTITIONED BY (country, name)
COMMENT 'Employees indexed by country and name.';
```

8.2 重建索引

如果用户指定了DEFERRED REBUILD，那么新索引将呈现空白状态。在任何时候，都可以进行第一次索引创建或者使用ALTER INDEX对索引进行重建：

```
ALTER INDEX employees_index
ON TABLE employees
PARTITION (country = 'US')
REBUILD;
```

如果省略掉PARTITION，那么将会对所有分区进行重建索引。

还没有一个内置的机制能够在底层的表或者某个特定的分区发生改变时，自动触发重建索引。但是，如果用户具有一个工作流来更新表分区中的数据的话，那么用户可能已经在其中某处使用到了第69页“众多的Alter Table语句”章节中所说明的ALTER TABLE ... TOUCH PARTITION(...)功能，同样地，在这个工作流中也可以对对应的索引执行重建索引语句ALTER INDEX ... REBUILD。

如果重建索引失败，那么在重建开始之前，索引将停留在之前的版本状态。从这种意义上说，重建索引操作是原子性的。

8.3 显示索引

下面这个命令将显示对于这个索引表对所有列所建立的索引：

```
SHOW FORMATTED INDEX ON employees;
```

关键字FORMATTED是可选的。增加这个关键字可以使输出中包含有列名称。用户还可以替换INDEX为INDEXES，这样输出中就可以列举出多个索引信息了。

8.4 删除索引

如果有索引表的话，删除一个索引将会删除这个索引表：

```
DROP INDEX IF EXISTS employees_index ON TABLE employees;
```

Hive不允许用户直接使用DROP TABLE语句之前删除索引表。而通常情况下，IF EXISTS都是可选的，其用于当索引不存在时避免抛出错误信息。

如果被索引的表被删除了，那么其对应的索引和索引表也会被删除。同样地，如果原始表的某个分区被删除了，那么这个分区对应的分区索引也同时会被删除掉。

8.5 实现一个定制化的索引处理器

在Hive Wiki页面具有实现一个定制化的索引处理器的完整的例子，链接是

https://cwiki.apache.org/confluence/display/Hive/IndexDev#CREATE_INDEX。其中还包含了索引的初步设计文档。当然，用户也是可以使用org.apache.hadoop.hive.ql.index.compact.CompactIndexHandler中的源代码作为例子来学习的。

创建好索引后，实现索引处理器的Java代码中也要做一些初始验证和为索引表（如果使用到索引表的话）定义模式的过程。同时还要实现重建索引处理逻辑，其会读取需要创建索引的表，然后写索引存储（例如索引表）。但索引被删除后，处理器还需要清理掉所有为索引所使用到的非表存储。如果需要，还要依赖Hive去删除索引表。处理器必须能够参与到优化查询中。

第9章 模式设计

Hive看上去以及实际行为都像一个关系型数据库。用户对如表和列这类术语比较熟悉，而且Hive提供的查询语言和用户之前使用过的SQL方言非常地相似。不过，Hive实现和使用的方式和传统的关系型数据库是非常不同的。通常，用户试图移植关系型数据库中的模式，而事实上Hive是反模式的。本章将重点介绍Hive中哪些模式是用户应该使用的，而又有哪些反模式是应该避免使用的。

9.1 按天划分的表

按天划分表就是一种模式，其通常会在表名中加入一个时间戳，例如表名为upply_2011_01_01、supply_2011_01_02，等等。这种每天一张表的方式在数据库领域是反模式的一种方式，但是因为实际情况下数据集增长得很快，这种方式应用还是比较广泛的。

```
hive> CREATE TABLE supply_2011_01_02 (id int, part string, quantity int);
hive> CREATE TABLE supply_2011_01_03 (id int, part string, quantity int);
hive> CREATE TABLE supply_2011_01_04 (id int, part string, quantity int);
hive> .... load data ...
hive> SELECT part,quantity supply_2011_01_02
> UNION ALL
> SELECT part,quantity from supply_2011_01_03
> WHERE quantity < 4;
```

对于Hive，这种情况下应该使用分区表。Hive通过WHERE子句中的表达式来选择查询所需要的指定的分区。这样的查询执行效率高，而且看起来清晰明了：

```
hive> CREATE TABLE supply (id int, part string, quantity int)
> PARTITIONED BY (int day);
hive> ALTER TABLE supply add PARTITION (day=20110102);
hive> ALTER TABLE supply add PARTITION (day=20110103);
hive> ALTER TABLE supply add PARTITION (day=20110102);
```

```
hive> .... load data ...  
hive> SELECT part,quantity FROM supply  
> WHERE day>=20110102 AND day<20110103 AND quantity < 4;
```

9.2 关于分区

Hive中分区的功能是非常有用的。这是因为Hive通常要对输入进行全盘扫描，来满足查询条件（这里我们先忽略掉Hive的索引功能）。通过创建很多的分区确实可以优化一些查询，但是同时可能会对其他一些重要的查询不利：

```
hive> CREATE TABLE weblogs (url string, time long )  
> PARTITIONED BY (day int, state string, city string);  
hive> SELECT * FROM weblogs WHERE day=20110102;
```

HDFS用于设计存储数百万的大文件，而非数十亿的小文件。使用过多分区可能导致的一个问题就是会创建大量的非必须的Hadoop文件和文件夹。一个分区就对应着一个包含有多个文件的文件夹。如果指定的表存在数百个分区，那么可能每天都会创建好几万个文件。如果保持这样的表很多年，那么最终就会超出NameNode对系统云数据信息的处理能力。因为NameNode必须要将所有的系统文件的元数据信息保存在内存中。虽然每个文件只需要少量字节大小的元数据（大约是150字节/文件），但是这样也会限制一个HDFS实例所能管理的文件总数的上限。而其他的文件系统，比如MapR和Amazon S3就没有这个限制。

MapReduce会将一个任务（job）转换成多个任务（task）。默认情况下，每个task都是一个新的JVM实例，都需要开启和销毁的开销。对于小文件，每个文件都会对应一个task。在一些情况下，JVM开启和销毁的时间中销毁可能会比实际处理数据的时间消耗要长！

因此，一个理想的分区方案不应该导致产生太多的分区和文件夹目录，并且每个目录下的文件应该足够得大，应该是文件系统中块大小的若干倍。

按时间范围进行分区的一个好的策略就是按照不同的时间粒度来确定合适大小的数据积累量，而且安装这个时间粒度。随着时间的推移，分区数量的增长是“均匀的”，而且每个分区下包含的文件大小至

少是文件系统中块的大小或块大小的数倍。这个平衡可以保持使分区足够大，从而优化一般情况下查询的数据吞吐量。同时有必要考虑这种粒度级别在未来是否是适用的，特别是查询中**WHERE**子句选择较小粒度的范围的情况：

```
hive> CREATE TABLE weblogs (url string, time long, state string, city string )  
> PARTITIONED BY (day int);  
hive> SELECT * FROM weblogs WHERE day=20110102;
```

另一个解决方案是使用两个级别的分区并且使用不同的维度。例如，第一个分区可能是按照天(day)进行划分的，而二级分区可能通过如州名 (state) 这样的地理区域进行划分：

```
hive> CREATE TABLE weblogs (url string, time long, city string )  
> PARTITIONED BY (day int, state string);  
hive> SELECT * FROM weblogs WHERE day=20110102;
```

然而，由于一些州可能会比其他州具有更多的数据，用户可能会发现**map task**处理数据时会出现不均，这是因为处理数据量多的州需要比处理数据量小的州要消耗更多的时间。

如果用户不能够找到好的、大小相对合适的分区方式的话，那么可以考虑使用第9.6节“分桶表数据存储”中介绍的分桶存储。

9.3 唯一键和标准化

关系型数据库通常使用唯一键、索引和标准化来存储数据集，通常是全部或者大部分存储到内存的。然而，Hive没有主键或基于序列密钥生成的自增键的概念。如果可以的话，应避免对非标准化数据进行连接 (JOIN) 操作。复杂的数据类型，如array、map和struct，有助于实现在单行中存储一对多数据。这并不是说不应该进行标准化，但是星形架构类型设计并非最优的。

避免标准化的主要的原因是为了最小化磁盘寻道，比如那些通常需要外键关系的情况。非标准化数据允许被扫描或写入到大的、连续的磁盘存储区域，从而优化磁盘驱动器的I/O性能。然而，非标准化数据可能导致数据重复，而且有更大的导致数据不一致的风险。

例如，思考下我们的运行示例——员工(employees)表。为了清晰地表述，这里再次做了一些修改：

```
CREATE TABLE employees (
  name      STRING,
  salary    FLOAT,
  subordinates ARRAY<STRING>,
  deductions MAP<STRING, FLOAT>
  address   STRUCT<street:STRING, city:STRING, state:STRING, zip:INT>);
```

这个例子中的数据模型从很多方面打破了传统的设计原则。

首先，我们非正式地使用name作为主键，而我们都知道名字往往不是唯一的！现在暂且忽略这个问题。一个关系模型中如果使用name作为键，那么从一个员工记录到经理记录应该有唯一的一个外键关系。这里我们使用了另一种方式来表达这个关系，即在subordinates数组字段中保存了这个员工所有的下属的名字。

其次，对于每名员工来说，其各项税收扣除额都是不同的，但是map的键都是一样的，即使用户使用“标记”(例如，整数)来作为键实际对应的值。一个常规的关系模型通常使用一个单独的、具有2个列的表来记录税收扣除项的扣除名称(或标志)和具体的值，而员工表和这个税收扣除项之间是一对多的关系。

最后，有些雇员还是有可能住在同一个地址的，但是我们为每个雇员都记录了其对应的住址，而不是使用一个雇员住址表，然后和雇员表建立一对一的关系。

下面轮到我们管理引用完整性（或处理结果），然后解决特定的发生了改变的数据中的重复数据。Hive本身没有提供方便的方式来对单行数据执行UPDATE操作。

不过，当用户的数据量达到数十TB到PB级别时，相对于这些局限性而言，优化执行速度显得更加重要。

9.4 同一份数据多种处理

Hive本身提供了一个独特的语法，它可以从一个数据源产生多个数据聚合，而无需每次聚合都要重新扫描一次。对于大的数据输入集

来说，这个优化可以节约非常可观的时间。我们会在第5章详细讨论这个问题。

例如，下面这2个查询都会从源表history表读取数据，然后导入到2个不同的表中：

```
hive> INSERT OVERWRITE TABLE sales
>   SELECT * FROM history WHERE action='purchased';
hive> INSERT OVERWRITE TABLE credits
>   SELECT * FROM history WHERE action='returned';
```

上面的查询，语法是正确的，不过执行效率低下。而如下这个查询可以达到同样的目的，却只需要扫描histroy表一次就可以：

```
hive> FROM history
>   INSERT OVERWRITE sales SELECT * WHERE action='purchased'
>   INSERT OVERWRITE credits SELECT * WHERE action='returned';
```

9.5 对于每个表的分区

很多的ETL处理过程会涉及到多个处理步骤，而每个步骤可能会产生一个或多个临时表，这些表仅供下一个job使用。起先可能会觉得将这些临时表进行分区不是那么有必要的。不过，想象一下这样的场景：由于查询或者原始数据处理的某个步骤出现问题而导致需要对好几天的输入数据重跑ETL过程。这时用户可能就需要执行那些一天执行一次的处理过程，来保证在所有的任务都完成之前不会有job将临时表覆盖重写。

例如，下面这个例子中设计了一个名为distinct_ip_in_logs的中间表，其会在后续处理步骤中使用到：

```
$ hive -hiveconf dt=2011-01-01
hive> INSERT OVERWRITE table distinct_ip_in_logs
>   SELECT distinct(ip) as ip from weblogs
>   WHERE hit_date='${hiveconf:dt}';

hive> CREATE TABLE state_city_for_day (state string,city string);

hive> INSERT OVERWRITE state_city_for_day
>   SELECT distinct(state,city) FROM distinct_ip_in_logs
>   JOIN geodata ON (distinct_ip_in_logs.ip=geodata.ip);
```

这种方式是有效的，不过当计算某一天的数据时会导致前一天的数据被INSERT OVERWRITE语句覆盖掉。如果同时运行两个这样的实例，用于处理不同日期的数据的话，那么它们就可能会相互影响到对方的结果数据。

一个更具鲁棒性的处理方法是在整个过程中使用分区。这样就不会存在同步问题。同时，这样还能带来一个好处，那就是可以允许用户对中间数据按日期进行比较：

```
$ hive -hiveconf dt=2011-01-01
hive> INSERT OVERWRITE table distinct_ip_in_logs
> PARTITION (hit_date=${dt})
> SELECT distinct(ip) as ip from weblogs
> WHERE hit_date='${hiveconf:dt}';

hive> CREATE TABLE state_city_for_day (state string,city string)
> PARTITIONED BY (hit_date string);

hive> INSERT OVERWRITE table state_city_for_day PARTITION(${hiveconf:df})
> SELECT distinct(state,city) FROM distinct_ip_in_logs
> JOIN geodata ON (distinct_ip_in_logs.ip=geodata.ip)
> WHERE (hit_date='${hiveconf:dt}');
```

这种方法的一个缺点是，用户将需要管理中间表并删除旧分区，不过这些任务也很容易实现自动化处理。

9.6 分桶表数据存储

分区提供一个隔离数据和优化查询的便利的方式。不过，并非所有的数据集都可形成合理的分区，特别是之前所提到过的要确定合适的划分大小这个疑虑。

分桶是将数据集分解成更容易管理的若干部分的另一个技术。

例如，假设有个表的一级分区是dt，代表日期，二级分区是user_id，那么这种划分方式可能会导致太多的小分区。回想下，如果用户是使用动态分区来创建这些分区的话，那么默认情况下，Hive会限制动态分区可以创建的最大分区数，用来避免由于创建太多的分区导致超过了文件系统的处理能力以及其他一些问题。因此，如下命令可能会执行失败：

```
hive> CREATE TABLE weblog (url STRING, source_ip STRING)
  > PARTITIONED BY (dt STRING, user_id INT);

hive> FROM raw_weblog
  > INSERT OVERWRITE TABLE page_view PARTITION(dt='2012-06-08', user_id)
  > SELECT server_name, url, source_ip, dt, user_id;
```

不过，如果我们对表**weblog**进行分桶，并使用**user_id**字段作为分桶字段，则字段值会根据用户指定的值进行哈希分发到桶中。同一个**user_id**下的记录通常会存储到同一个桶内。假设用户数要比桶数多得多，那么每个桶内就将会包含多个用户的记录：

```
hive> CREATE TABLE weblog (user_id INT, url STRING, source_ip STRING)
  > PARTITIONED BY (dt STRING)
  > CLUSTERED BY (user_id) INTO 96 BUCKETS;
```

不过，将数据正确地插入到表的过程完全取决于用户自己！
CREATE TABLE语句中所规定的信息仅仅定义了元数据，而不影响实际填充表的命令。

下面介绍如何在使用INSERT ... TABLE语句时，正确地填充表。首先，我们需要设置一个属性来强制Hive为目标表的分桶初始化过程设置一个正确的reducer个数。然后我们再执行一个查询来填充分区。例如：

```
hive> SET hive.enforce.bucketing = true;

hive> FROM raw_logs
  > INSERT OVERWRITE TABLE weblog
  > PARTITION (dt='2009-02-25')
  > SELECT user_id, url, source_ip WHERE dt='2009-02-25';
```

如果我们没有使用**hive.enforce.bucketing**属性，那么我们就需要自己设置和分桶个数相匹配的reducer个数，例如，使用**set mapred.reduce.tasks=96**，然后在INSERT语句中，需要在SELECT语句后增加CLUSTER BY语句。



警告

对于所有表的元数据，指定分桶并不能保证表可以正确地填充。用户可以根据前面的示例来确保是否正确地填充了表。

分桶有几个优点。因为桶的数量是固定的，所以它没有数据波动。桶对于抽样再合适不过。如果两个表都是按照user_id进行分桶的话，那么Hive可以创建一个逻辑上正确的抽样。分桶同时有利于执行高效的map-side JOIN，正如我们在第6.4.9节“map-side JOIN”中讨论过的一样。

9.7 为表增加列

Hive允许在原始数据文件之上定义一个模式，而不像很多的数据仓库那样，要求必须以特定的格式转换和导入数据。这样的分离方式的好处是，当为数据文件增加新的字段时，可以容易地适应表定义的模式。

Hive提供了SerDe抽象，其用于从输入中提取数据。SerDe同样用于输出数据，尽管输出功能并非经常使用，因为Hive主要用于查询。一个SerDe通常是从左到右进行解析的。通过指定的分隔符将行分解成列。SerDe通常是非常宽松的。例如，如果某行的字段个数比预期的要少，那么缺少的字段将返回null。如果某行的字段个数比预期的要多，那么多出的字段将会被省略掉。增加新字段的命令只需要一条ALTER TABLE ADD COLUMN命令就可完成。因为日志格式通常是对已有字段增加更多信息，所以这样是非常有用的：

```
hive> CREATE TABLE weblogs (version LONG, url STRING)
  > PARTITIONED BY (hit_date int)
  > ROW FORMAT DELIMITED FIELDS TERMINATED BY '\t';

hive> ! cat log1.txt
1 /mystuff
1 /toys

hive> LOAD DATA LOCAL INPATH 'log1.txt' int weblogs partition(20110101);

hive> SELECT * FROM weblogs;
1 /mystuff 20110101
1 /toys 20110101
```

随着时间的推移，可能会为底层数据增加一个新字段。如下这个例子就是展示为数据新增user_id字段的过程。需要注意的是，一些旧的原始数据文件可能不包含这个字段：

```
hive> ! cat log2.txt
2 /cars bob
2 /stuff terry
```

```

hive> ALTER TABLE weblogs ADD COLUMNS (user_id string);

hive> LOAD DATA LOCAL INPATH 'log2.txt' int weblogs partition(20110102);

hive> SELECT * from weblogs
1 /mystuff      20110101 NULL
1 /toys         20110101 NULL
2 /cars          20110102 bob
2 /stuff         20110102 terry

```

需要注意的是，通过这种方式，无法在已有字段的开始或者中间增加新字段。

9.8 使用列存储表

Hive通常使用行式存储，不过Hive也提供了一个列式SerDe来以混合列式格式存储信息。虽然这种格式是可以用于任意类型的数据的，不过对于某些数据集使用这种方式是最优的。

9.8.1 重复数据

假设有足够多的行，像state字段和age字段这样的列将会有很多重复的数据。这种类型的数据如果使用列式存储将会非常好，如表9-1所示。

表9-1 有3个字段的样例表

state	uid	age
NY	Bob	40
NJ	Sara	32
NY	Peter	14
NY	Sandra	4

9.8.2 多列

表9-2具有非常多的字段。

表9-2 有众多字段的样例表

state	uid	age	server	tz	many_more...
NY	Bob	40	web1	est	stuff
NJ	Sara	32	web1	est	stuff
NY	Peter	14	web3	pst	stuff
NY	Sandra	4	web45	pst	stuff

查询通常只会使用到一个字段或者很少的一组字段。基于列式存储将会使分析表数据执行得更快：

```
hive> SELECT distinct(state) from weblogs;
NY
NJ
```

用户可以参考第15.3.2节“RCFile”内容来看看如何使用这种格式。

9.9 (几乎) 总是使用压缩

几乎在所有情况下，压缩都可以使磁盘上存储的数据量变小，这样可以通过降低I/O来提高查询执行速度。Hive可以无缝地使用很多压缩类型。不使用压缩唯一令人信服的理由就是产生的数据用于外部系统，或者非压缩格式（例如文本格式）是最兼容的。

但是压缩和解压缩都会消耗CPU资源。MapReduce任务往往是I/O密集型的，因此CPU开销通常不是问题。不过，对于工作流这样的

CPU密集型的场景，例如一些机器学习算法，压缩实际上可能会从更多必要的操作中获取宝贵的CPU资源，从而降低性能。

第11章“其他文件格式和压缩方法”中有关于如何使用压缩更详细的介绍。

第10章 调优

HiveQL是一种声明式语言，用户会提交声明式的查询，而Hive会将其转换成MapReduce job。大多数情况，用户不需要了解Hive内部是如何工作的，这样可以专注于手头上的事情。而内部复杂的查询解析、规划、优化和执行过程是由Hive开发团队多年的艰难工作来实现的，不过大部分时间用户可以直接无视这些内部逻辑。

不过，当用户对于Hive具有越来越多的经验后，学习下Hive背后的理论知识以及底层的一些实现细节，会让用户更加高效地使用Hive。

本章将会分几种不同的议题来介绍Hive性能调优。一些调优涉及到调整配置参数的值（就像“调整旋钮”一样），而其他一些调优过程则包括启用或者禁用某些特定的特性。

10.1 使用EXPLAIN

学习Hive是如何工作的（在读完本书之后）第一个步骤就是学习EXPLAIN功能，其可以帮助我们学习Hive是如何将查询转化成MapReduce任务的。

思考下面这个例子：

```
hive> DESCRIBE onecol;
number int

hive> SELECT * FROM onecol;
5
5
4

hive> SELECT SUM(number) FROM onecol;
14
```

现在，我们在前面例子中最后一个查询语句前加上EXPLAIN关键字，然后来查询下查询计划和其他一些信息。这个查询本身是不会执行的。

```
hive> EXPLAIN SELECT SUM(number) FROM onecol;
```

上面查询语句的输出需要一些解释和实践才能够理解。

首先，会打印出抽象语法树。它表明Hive是如何将查询解析成token(符号)和literal(字面值)的，是第一步将查询转化到最终结果的一部分。

```
ABSTRACT SYNTAX TREE:  
(TOK_QUERY  
  (TOK_FROM (TOK_TABREF (TOK_TABNAME onecol)))  
  (TOK_INSERT (TOK_DESTINATION (TOK_DIR TOK_TMP_FILE)))  
  (TOK_SELECT  
    (TOK_SELEXPR  
      (TOK_FUNCTION sum (TOK_TABLE_OR_COL number))))))
```

(为了适应页面的展示，这里对实际的输出信息进行了缩进处理。)

对于那些不熟悉解析器和分词器的用户来说，这个看起来令人难以应付。不过，即使用户是这个领域的新手，也是可以来研究下这个输出信息的。这样可以方便用户了解Hive是怎么处理SQL语句的。

(作为第一步，用户可以忽略掉TOK_这个前缀来查看输出信息。)

尽管我们的查询会将其输出写入到控制台，但Hive实际上会先将输出写入到一个临时文件中，正如下面输出信息中所表示的：

```
'(TOK_INSERT (TOK_DESTINATION (TOK_DIR TOK_TMP_FILE)))'
```

接下来，我们可以看到列名number，以及表名onecol，还有sum函数。

一个Hive任务会包含有一个或多个*stage*(阶段)，不同的*stage*间会存在着依赖关系。正如用户可以预料到的，越复杂的查询通常将会引入越多的*stage*，而通常*stage*越多就需要越多的时间来完成任务。

一个*stage*可以是一个MapReduce任务，也可以是一个抽样阶段，或者一个合并阶段，还可以是一个limit阶段，以及Hive需要的其他某个任务的一个阶段。默认情况下，Hive会一次只执行一个*stage*(阶段)，不过我们稍后将在第10.6节“并行执行”中讨论如何并行执行。

某些阶段执行时间很短，像将文件转移到其他路径下这样的操作；其他一些阶段如果数据量小，那么执行也是很快的，即使有时它们需要一个map过程或reduce过程：

```
STAGE DEPENDENCIES:  
  Stage-1 is a root stage  
  Stage-0 is a root stage
```

STAGE PLAN部分比较冗长也比较复杂。Stage-1包含了这个job的大部分处理过程，而且会触发一个MapReduce job。TableScan以这个表作为输入，然后会产生一个只有字段number的输出。Group By Operator会应用到sum(number)，然后会产生一个输出字段_col0(这是为临时结果字段按规则起的临时字段名)。这些都是发生在job的map处理阶段过程，也就是都是位于Map Operator Tree下面的：

```
STAGE PLANS:  
  Stage: Stage-1  
    Map Reduce  
      Alias -> Map Operator Tree:  
        onecol  
          TableScan  
            alias: onecol  
            Select Operator  
              expressions:  
                expr: number  
                type: int  
            outputColumnNames: number  
            Group By Operator  
              aggregations:  
                expr: sum(number)  
            bucketGroup: false  
            mode: hash  
            outputColumnNames: _col0  
            Reduce Output Operator  
              sort order:  
              tag: -1  
              value expressions:  
                expr: _col0  
                type: bigint
```

在reduce过程这边，也就是Reduce Operator Tree下面，我们可以看到相同的Group by Operator，但是这次其应用到的是对_col0字段进行sum操作。最后，在reducer中我们看到了File Output Operator，其说明了输出结果将是文本格式，是基于字符串的输出格式：

HiveIgnoreKeyTextOutputFormat:

```
Reduce Operator Tree:  
Group By Operator  
  aggregations:  
    expr: sum(VALUE._col0)  
  bucketGroup: false  
  mode: mergepartial  
  outputColumnNames: _col0  
Select Operator  
  expressions:  
    expr: _col0  
    type: bigint  
  outputColumnNames: _col0  
File Output Operator  
  compressed: false  
  GlobalTableId: 0  
  table:  
    input format: org.apache.hadoop.mapred.TextInputFormat  
    output format:  
      org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat
```

因为这个job没有LIMIT语句，因此Stage-0阶段是一个没有任何操作的阶段：

```
Stage: Stage-0  
Fetch Operator  
  limit: -1
```

理解Hive是如何对每个查询进行解析和计划的复杂的细节并非总是有用的。不过，这是分析复杂的或执行效率低的查询的一个不错的方式，特别是当我们需要尝试各种各样的调优方式时。我们可以在“逻辑”层查看到这些调整会产生什么样的影响，这样可以关联到性能的度量。

10.2 EXPLAIN EXTENDED

使用EXPLAIN EXTENDED语句可以产生更多的输出信息。为了方便起见，我们不会展示完整的输出，不过我们将会展示Reduce Operator Tree来演示输出的不同点：

```
Reduce Operator Tree:  
Group By Operator  
  aggregations:  
    expr: sum(VALUE._col0)  
  bucketGroup: false  
  mode: mergepartial  
  outputColumnNames: _col0  
Select Operator
```

```

expressions:
  expr: _col0
  type: bigint
outputColumnNames: _col0
File Output Operator
  compressed: false
  GlobalTableId: 0
  directory: file:/tmp/edward/hive_2012-[long number]/-ext-10001
  NumFilesPerFileSink: 1
  Stats Publishing Key Prefix:
    file:/tmp/edward/hive_2012-[long number]/-ext-10001/
table:
  input format: org.apache.hadoop.mapred.TextInputFormat
  output format:
    org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat
  properties:
    columns _col0
    columns.types bigint
    escape.delim \
    serialization.format 1
  TotalFiles: 1
  GatherStats: false
  MultiFileSpray: false

```

强烈建议用户比较下这两个Reduce Operator Tree下的输出。

10.3 限制调整

LIMIT语句是大家经常使用到的，经常使用CLI的用户都会使用到。不过，在很多情况下LIMIT语句还是需要执行整个查询语句，然后再返回部分结果的。因为这种情况通常是浪费的，所以应该尽可能地避免出现这种情况。Hive有一个配置属性可以开启，当使用LIMIT语句时，其可以对源数据进行抽样：

```

<property>
  <name>hive.limit.optimize.enable</name>
  <value>true</value>
  <description>Whether to enable to optimization to
    try a smaller subset of data for simple LIMIT first.</description>
</property>

```

一旦属性hive.limit.optimize.enable的值设置为true，那么还会有两个参数可以控制这个操作，也就是hive.limit.row.max.size和hive.limit.optimize.limit.file：

```

<property>
  <name>hive.limit.row.max.size</name>
  <value>100000</value>

```

```
<description>When trying a smaller subset of data for simple LIMIT,  
    how much size we need to guarantee each row to have at least.  
</description>  
</property>  
  
<property>  
<name>hive.limit.optimize.limit.file</name>  
<value>10</value>  
<description>When trying a smaller subset of data for simple LIMIT,  
    maximum number of files we can sample.</description>  
</property>
```

这个功能的一个缺点就是，有可能输入中有用的数据永远不会被处理到，例如，像任意的一个需要reduce步骤的查询，JOIN和GROUP BY操作，以及聚合函数的大多数调用，等等，将会产生很不同的结果。也许这个差异在很多情况下是可以接受的，但是重要的是要理解。

10.4 JOIN优化

在第6.4.2节“JOIN优化”和第6.4.9节“map-side JOIN”中我们讨论过如何优化job性能。这里我们不会再次重新进行说明，不过需要提醒自己要清楚哪个表是最大的，并将最大的表放置在JOIN语句的最右边，或者直接使用/* streamtable(table_name) */语句指出。

如果所有表中有一个表足够得小，是可以完成载入到内存中的，那么这时Hive可以执行一个map-side JOIN，这样可以减少reduce过程，有时甚至可以减少某些map task任务。有时候即使某些表不适合载入内存也可以使用mapJOIN，因为减少reduce阶段可能比将不太大的表分发到每个map task中会带来更多的好处。

10.5 本地模式

大多数的Hadoop Job是需要Hadoop提供的完整的可扩展性来处理大数据集的。不过，有时Hive的输入数据量是非常小的。在这种情况下，为查询触发执行任务的时间消耗可能会比实际job的执行时间要多得多。对于大多数这种情况，Hive可以通过本地模式在单台机器上（或某些时候在单个进程中）处理所有的任务。对于小数据集，执行时间可以明显被缩短。

用户可以按照如下这个例子中所演示的方式，在执行过程中临时启用本地模式：

```
hive> set oldjobtracker=${hiveconf:mapred.job.tracker};  
hive> set mapred.job.tracker=local;  
hive> set mapred.tmp.dir=/home/edward/tmp;  
hive> SELECT * from people WHERE firstname=bob;  
...  
hive> set mapred.job.tracker=${oldjobtracker};
```

用户可以通过设置属性hive.exec.mode.local.auto的值为true，来让Hive在适当的时候自动启动这个优化。通常用户可以将这个配置写在\$HOME/.hiverc文件中。

如果希望对所有的用户都使用这个配置，那么可以将这个配置项增加到\$HIVE_HOME/conf/hive-site.xml文件中：

```
<property>  
  <name>hive.exec.mode.local.auto</name>  
  <value>true</value>  
  <description>  
    Let hive determine whether to run in local mode automatically  
  </description>  
</property>
```

10.6 并行执行

Hive会将一个查询转化成一个或者多个阶段。这样的阶段可以是MapReduce阶段、抽样阶段、合并阶段、limit阶段，或者Hive执行过程中可能需要的其他阶段。默认情况下，Hive一次只会执行一个阶段。不过，某个特定的job可能包含众多的阶段，而这些阶段可能并非完全互相依赖的，也就是说有些阶段是可以并行执行的，这样可能使得整个job的执行时间缩短。不过，如果有更多的阶段可以并行执行，那么job可能就越快完成。

通过设置参数hive.exec.parallel值为true，就可以开启并发执行。不过，在共享集群中，需要注意下，如果job中并行执行的阶段增多，那么集群利用率就会增加：

```
<property>
  <name>hive.exec.parallel</name>
  <value>true</value>
  <description>Whether to execute jobs in parallel</description>
</property>
```

10.7 严格模式

Hive提供了一个严格模式，可以防止用户执行那些可能产生意想不到的不好的影响的查询。

通过设置属性hive.mapred.mode值为strict可以禁止3种类型的查询。

其一，对于分区表，除非WHERE语句中含有分区字段过滤条件来限制数据范围，否则不允许执行。换句话说，就是用户不允许扫描所有分区。进行这个限制的原因是，通常分区表都拥有非常大的数据集，而且数据增加迅速。没有进行分区限制的查询可能会消耗令人不可接受的巨大资源来处理这个表：

```
hive> SELECT DISTINCT(planner_id) FROM fracture_ins WHERE planner_id=5;
FAILED: Error in semantic analysis: No Partition Predicate Found for
Alias "fracture_ins" Table "fracture_ins"
```

如下这个语句在WHERE语句中增加了一个分区过滤条件（也就是限制了表分区）：

```
hive> SELECT DISTINCT(planner_id) FROM fracture_ins
  > WHERE planner_id=5 AND hit_date=20120101;
... normal results ...
```

其二，对于使用了ORDER BY语句的查询，要求必须使用LIMIT语句。因为ORDER BY为了执行排序过程会将所有的结果数据分发到同一个reducer中进行处理，强制要求用户增加这个LIMIT语句可以防止reducer额外执行很长一段时间：

```
hive> SELECT * FROM fracture_ins WHERE hit_date>2012 ORDER BY planner_id;
FAILED: Error in semantic analysis: line 1:56 In strict mode,
limit must be specified if ORDER BY is present planner_id
```

只需要增加LIMIT语句就可以解决这个问题：

```
hive> SELECT * FROM fracture_ins WHERE hit_date>2012 ORDER BY planner_id
> LIMIT 100000;
... normal results ...
```

其三，也就是最后一种情况，就是限制笛卡尔积的查询。对关系型数据库非常了解的用户可能期望在执行JOIN查询的时候不使用ON语句而是使用WHERE语句，这样关系型数据库的执行优化器就可以高效地将WHERE语句转化成那个ON语句。不幸的是，Hive并不会执行这种优化，因此，如果表足够大，那么这个查询就会出现不可控的情况：

```
hive> SELECT * FROM fracture_act JOIN fracture_ads
> WHERE fracture_act.planner_id = fracture_ads.planner_id;
FAILED: Error in semantic analysis: In strict mode, cartesian product
is not allowed. If you really want to perform the operation,
+set hive.mapred.mode=nonstrict+
```

下面这个才是个正确的使用JOIN和ON语句的查询：

```
hive> SELECT * FROM fracture_act JOIN fracture_ads
> ON (fracture_act.planner_id = fracture_ads.planner_id);
... normal results ...
```

10.8 调整mapper和reducer个数

Hive通过将查询划分成一个或者多个MapReduce任务达到并行的目的。每个任务都可能具有多个mapper和reducer任务，其中至少有一些是可以并行执行的。确定最佳的mapper个数和reducer个数取决于多个变量，例如输入的数据量大小以及对这些数据执行的操作类型等。

保持平衡性是有必要的。如果有太多的mapper或reducer任务，就会导致启动阶段、调度和运行job过程中产生过多的开销；而如果设置的数量太少，那么就可能没有充分利用好集群内在的并行性。

当执行的Hive查询具有reduce过程时，CLI控制台会打印出调优后的reducer个数。下面我们来看一个包含有GROUP BY语句的例子，因为这种查询总是需要reduce过程的。与此相反，很多其他查询会转换成只需要map阶段的任务：

```
hive> SELECT pixel_id, count FROM fracture_ins WHERE hit_date=20120119
> GROUP BY pixel_id;
```

```
Total MapReduce jobs = 1
Launching Job 1 out of 1
Number of reduce tasks not specified. Estimated from input data size: 3
In order to change the average load for a reducer (in bytes):
  set hive.exec.reducers.bytes.per.reducer=<number>
In order to limit the maximum number of reducers:
  set hive.exec.reducers.max=<number>
In order to set a constant number of reducers:
  set mapred.reduce.tasks=<number>
...
```

Hive是按照输入的数据量大小来确定reducer个数的。我们可以通过dfs -count命令来计算输入量大小，这个命令和Linux中的du -s命令类似；其可以计算指定目录下所有数据的总大小：

```
[edward@etl02 ~]$ hadoop dfs -count /user/media6/fracture/ins/* | tail -4
1 8 2614608737 hdfs://.../user/media6/fracture/ins/hit_date=20120118
1 7 2742992546 hdfs://.../user/media6/fracture/ins/hit_date=20120119
1 17 2656878252 hdfs://.../user/media6/fracture/ins/hit_date=20120120
1 2 362657644 hdfs://.../user/media6/fracture/ins/hit_date=20120121
```

（为了方便排版查看，我们对实际的数据进行了格式化并省略掉了一些详细信息。）

属性hive.exec.reducers.bytes.per.reducer的默认值是1GB。如果将这个属性值调整为750MB的话，那么下面这个任务Hive就会使用4个reducer：

```
hive> set hive.exec.reducers.bytes.per.reducer=7500000000;
hive> SELECT pixel_id, count(1) FROM fracture_ins WHERE hit_date=20120119
  > GROUP BY pixel_id;
Total MapReduce jobs = 1
Launching Job 1 out of 1
Number of reduce tasks not specified. Estimated from input data size: 4
...
```

默认值通常情况下是比较合适的。不过，有些情况下查询的map阶段会产生比实际输入数据量要多得多的数据。如果map阶段产生的数据量非常多，那么根据输入的数据量大小来确定的reducer个数就显得有些少了。同样地，map阶段也可能会过滤掉输入数据集中的很大部分的数据而这时可能需要少量的reducer就满足计算了。

一个快速的进行验证的方式就是将reducer个数设置为固定的值，而无需Hive来计算得到这个值。如果用户还记得的话，Hive的默认reducer个数应该是3。可以通过设置属性mapred.reduce.tasks的值为不

同的值来确定是使用较多还是较少的reducer来缩短执行时间。需要记住，受外部因素影响，像这样的标杆值十分复杂，例如其他用户并发执行job的情况。Hadoop需要消耗好几秒时间来启动和调度map和reduce任务（task）。在进行性能测试的时候，要考虑到这些影响因子，特别是job比较小的时候。

当在共享集群上处理大任务时，为了控制资源利用情况，属性hive.exec.reducers.max显得非常重要。一个Hadoop集群可以提供的map和reduce资源个数（也称为“插槽”），是固定的。某个大job可能就会消耗完所有的插槽，从而导致其他job无法执行。通过设置属性hive.exec.reducers.max可以阻止某个查询消耗太多的reducer资源。有必要将这个属性配置到\$HIVE_HOME/conf/hive-site.xml文件中。对这个属性值大小的一个建议的计算公式如下：

(集群总Reduce槽位个数*1.5) / (执行中的查询的平均个数)

1.5倍数是一个经验系数，用于防止未充分利用集群的情况。

10.9 JVM重用

JVM重用是Hadoop调优参数的内容，其对Hive的性能具有非常大的影响，特别是对于很难避免小文件的场景或task特别多的场景，这类场景大多数执行时间都很短。

Hadoop的默认配置通常是使用派生JVM来执行map和reduce任务的。这时JVM的启动过程可能会造成相当大的开销，尤其是执行的job包含有成百上千个task任务的情况。JVM重用可以使得JVM实例在同一个job中重新使用N次。N的值可以在Hadoop的mapred-site.xml文件（位于\$HADOOP_HOME/conf目录下）中进行设置：

```
<property>
  <name>mapred.job.reuse.jvm.num.tasks</name>
  <value>10</value>
  <description>How many tasks to run per jvm. If set to -1, there is no limit.
  </description>
</property>
```

这个功能的一个缺点是，开启JVM重用将会一直占用使用到的task插槽，以便进行重用，直到任务完成后才能释放。如果某个“不平

衡的”的job中有某几个reduce task执行的时间要比其他reduce task消耗的时间多得多的话，那么保留的插槽就会一直空闲着却无法被其他的job使用，直到所有的task都结束了才会释放。

10.10 索引

索引可以用来加快含有GROUP BY语句的查询的计算速度。

Hive从v0.8.0版本后增加了一个bitmap索引实现。Bitmap索引一般在指定的列排重后的值比较小时进行使用。请参考第8.1.1节“Bitmap索引”中的详细说明。

10.11 动态分区调整

正如在第5.2.1节“动态分区插入”中所讲解过的一样，动态分区INSERT语句可以通过简单的SELECT语句向分区表中创建很多新的分区。

这是一个非常强大的功能，不过如果分区的个数非常得多，那么就会在系统中产生大量的输出控制流。对于Hadoop来说，这个种情况并不是常见的使用场景，因此，其通常会一次创建很多的文件，然后会向这些文件中写入大量的数据。

跳出这些框框，Hive可以通过配置限制动态分区插入允许创建的分区数在1000个左右。虽然太多的分区对于表来说并不好，不过，通常还是将这个值设置的更大以便这些查询执行。

首先，通常在hive-site.xml配置文件中设置动态分区模式为严格模式（也就是属性值为strict），这个配置在第10.7节“严格模式”中有介绍过。开启严格模式的时候，必须保证至少有一个分区是静态的，正如在第5.2.1节“动态分区插入”中所展示的。

```
<property>
  <name>hive.exec.dynamic.partition.mode</name>
  <value>strict</value>
  <description>In strict mode, the user must specify at least one
  static partition in case the user accidentally overwrites all
  partitions.</description>
</property>
```

然后，可以增加一些相关的属性信息，例如通过如下属性来限制查询可以创建的最大动态分区个数：

```
<property>
  <name>hive.exec.max.dynamic.partitions</name>
  <value>300000</value>
  <description>Maximum number of dynamic partitions allowed to be
  created in total.</description>
</property>

<property>
  <name>hive.exec.max.dynamic.partitions.pernode</name>
  <value>10000</value>
  <description>Maximum number of dynamic partitions allowed to be
  created in each mapper/reducer node.</description>
</property>
```

还有一个配置是用来控制DataNode上一次可以打开的文件的个数。这个参数必须设置在DataNode的\$HADOOP_HOME/conf/hdfs-site.xml配置文件中。

在Hadoop v0.20.2版本中，这个属性的默认值是256，太小了。这个值会影响到最大的线程数和资源数，因此，也并不推荐将这个属性值设置为一个极大值。同时需要注意的是，在Hadoop v0.20.2版本中，更改这个属性值需要重启DataNode才能够生效：

```
<property>
  <name>dfs.datanode.max.xcievers</name>
  <value>8192</value>
</property>
```

10.12 推测执行

推测执行是Hadoop中的一个功能，其可以触发执行一些重复的任务（task）。尽管这样会因对重复的数据进行计算而导致消耗更多的计算资源，不过这个功能的目标是通过加快获取单个task的结果以及进行侦测将执行慢的TaskTracker加入到黑名单的方式来提高整体的任务执行效率。

Hadoop的推测执行功能由\$HADOOP_HOME/conf/mapred-site.xml文件中的如下2个配置项控制着：

```
<property>
  <name>mapred.map.tasks.speculative.execution</name>
  <value>true</value>
  <description>If true, then multiple instances of some map tasks
  may be executed in parallel.</description>
</property>

<property>
  <name>mapred.reduce.tasks.speculative.execution</name>
  <value>true</value>
  <description>If true, then multiple instances of some reduce tasks
  may be executed in parallel.</description>
</property>
```

不过，Hive本身也提供了配置项来控制reduce-side的推测执行：

```
<property>
  <name>hive.mapred.reduce.tasks.speculative.execution</name>
  <value>true</value>
  <description>Whether speculative execution for
  reducers should be turned on. </description>
</property>
```

关于调优这些推测执行变量，还很难给一个具体的建议。如果用户对于运行时的偏差非常敏感的话，那么可以将这些功能关闭掉。如果用户因为输入数据量很大而需要执行长时间的map或者reduce task的话，那么启动推测执行造成的浪费是非常巨大的。

10.13 单个MapReduce中多个GROUP BY

另一个特别的优化试图将查询中的多个GROUP BY操作组装到单个MapReduce任务中。如果想启动这个优化，那么需要一组常用的GROUP BY键：

```
<property>
  <name>hive.multigrouby.singlemr</name>
  <value>false</value>
  <description>Whether to optimize multi group by query to generate single M/R
  job plan. If the multi group by query has common group by keys, it will be
  optimized to generate single M/R job.</description>
</property>
```

10.14 虚拟列

Hive提供了2种虚拟列：一种用于将要进行划分的输入文件名，另一种用于文件中的块内偏移量。当Hive产生了非预期的或null的返回结果时，可以通过这些虚拟列诊断查询。通过查询这些“字段”，用户可以查看到哪个文件甚至哪行数据导致出现问题：

```
hive> set hive.exec.rowoffset=true;

hive> SELECT INPUT__FILE__NAME, BLOCK__OFFSET__INSIDE__FILE, line
>   FROM hive_text WHERE line LIKE '%hive%' LIMIT 2;
har://file/user/hive/warehouse/hive_text/folder=docs/
data.har//user/hive/warehouse/hive_text/folder=docs/README.txt 2243
  http://hive.apache.org/

har://file/user/hive/warehouse/hive_text/folder=docs/
data.har//user/hive/warehouse/hive_text/folder=docs/README.txt 3646
- Hive 0.8.0 ignores the hive-default.xml file, though we continue
```

（为了方便排版和查看，我们对输出进行了格式调整并且在输出行中间增加了空行。）

第3种虚拟列提供了文件的行偏移量。这个需要通过如下参数显式地启用：

```
<property>
  <name>hive.exec.rowoffset</name>
  <value>true</value>
  <description>Whether to provide the row offset virtual column</description>
</property>
```

这样设置后就可以在类似于如下的查询中使用了：

```
hive> SELECT INPUT__FILE__NAME, BLOCK__OFFSET__INSIDE__FILE,
>   ROW__OFFSET__INSIDE__BLOCK
>   FROM hive_text WHERE line LIKE '%hive%' limit 2;
file:/user/hive/warehouse/hive_text/folder=docs/README.txt      2243 0
file:/user/hive/warehouse/hive_text/folder=docs/README.txt      3646 0
```

第11章 其他文件格式和压缩方法

Hive的一个独特的功能就是：Hive不会强制要求将数据转换成特定的格式才能使用。Hive利用Hadoop的InputFormat API来从不同的数据源读取数据，例如文本格式、sequence文件格式，甚至用户自定义格式。同样地，使用OutputFormat API也可以将数据写成不同的格式。

尽管Hadoop的文件系统支持对于非压缩数据的线性扩展存储，但是对数据进行压缩还是有很大好处的。压缩通常都会节约可观的磁盘空间，例如，基于文本的文件可以压缩40%甚至更高比例。压缩同样可以增加吞吐量和性能。这看上去似乎并不合常理，因为压缩和解压缩会增加额外的CPU开销，不过，通过减少载入内存的数据量而提高I/O吞吐量会更加提高网络传输性能。

Hadoop的job通常是I/O密集型而不是CPU密集型的。如果是这样的话，压缩可以提高性能。不过，如果用户的job是CPU密集型的话，那么使用压缩可能会降低执行性能。确定是否进行压缩的唯一方法就是尝试不同的选择，并测量对比执行结果。

11.1 确定安装编解码器

基于用户所使用的Hadoop版本，会提供不同的编解码器。Hive中可以通过set命令查看Hive配置文件中或Hadoop配置文件中配置的值。

通过查看属性io.compression.codec，可以看到编解码器之间是按照逗号进行分割的：

```
# hive -e "set io.compression.codecs"
io.compression.codecs=org.apache.hadoop.io.compress.GzipCodec,
org.apache.hadoop.io.compress.DefaultCodec,
org.apache.hadoop.io.compress.BZip2Codec,
org.apache.hadoop.io.compress.SnappyCodec
```

11.2 选择一种压缩编/解码器

使用压缩的优势是可以最小化所需要的磁盘存储空间，以及减小磁盘和网络I/O操作。不过，文件压缩过程和解压缩过程会增加CPU开销。因此，对于压缩密集型的job最好使用压缩，特别是有额外的CPU资源或磁盘存储空间比较稀缺的情况。

所有最新的那些Hadoop版本都已经内置支持GZIP和BZip2压缩方案了，包括加速对这些格式的压缩和解压缩的本地Liunx库。绑定支持Snappy压缩是最近才增加的，不过，如果用户当前使用的Hadoop版本不支持该功能的话，那么自行增加相关的库即可^[1]。另外，还有一种常用的压缩方案，即LZO压缩^[2]。

那么，为什么我们需要不同的压缩方案呢？每一个压缩方案都在压缩/解压缩速度和压缩率间进行权衡。BZip2压缩率最高，但是同时需要消耗最多的CPU开销。GZip是压缩率和压缩/解压缩速度上的下一个选择。因此，如果磁盘空间利用率和I/O开销都需要考虑的话，那么这2种压缩方案都是有吸引力的。

LZO和Snappy压缩率相比前面的2种要小但是压缩/解压缩速度要快，特别是解压缩过程。如果相对于磁盘空间和I/O开销，频繁读取数据所需的解压缩速度更重要的话，那么它们将是不错的选择。

另一个需要考虑的因素是压缩格式的文件是否是可分割的。MapReduce需要将非常大的输入文件分割成多个划分（通常一个文件块对应一个划分，也就是64MB的倍数），其中每个划分会被分发到一个单独的map进程中。只有当Hadoop知道文件中记录的边界时才可以进行这样的分割。对于文本文件，每一行都是一条记录，但是GZip和Snappy将这些边界信息掩盖掉了。不过，BZip2和LZO提供了块（BLOCK）级别的压缩，也就是每个块中都含有完整的记录信息，因此Hadoop可以在块边界级别对这些文件进行划分。

虽然GZIip和Snappy压缩的文件不可划分，但是并不能因此而排除它们。当用户创建文件的时候，可以将文件分割成期望的文件大小。通常输出文件的个数等于reducer的个数。也就是说如果用户使用了N个reducer，那么通常就会得到N个输出文件。需要注意的是，如果有 一个不可分割的文件特别的大，那么就会出现一个单独的task来读取整个文件，进行处理。

关于压缩我们还有更多的内容要说，不过我们推荐用户参考 Tom White (O'Reilly) 所著的《Hadoop 编程指南》一书，这里，我们会专注于在 Hive 中如何使用指定的格式。

从 Hive 的角度来看，对于文件格式，有 2 个方面的内容需要说明。一个方面是文件是怎样分隔成行（记录）的。文本文件使用 \n（换行符）作为默认的行分隔符。当用户没有使用默认的文本文件格式时，用户需要告诉 Hive 使用的 InputFormat 和 OutputFormat 是什么。事实上，用户需要指定对于输入和输出格式实现的 Java 类的名称。InputFormat 中定义了如何读取划分，以及如何将划分分割成记录，而 OutputFormat 中定义了如何将这些划分写回到文件或控制台输出中。

第 2 个方面是记录是如何分割成字段（或列）的。Hive 使用 ^A 作文本文件中默认的字段分隔符。Hive 使用 SerDe（也就是序列化/反序列化的简写）作为对输入记录（反序列化）进行分割以及写记录（序列化）的“模板”。这时，用户只需要指定可以完成这 2 部分工作的一个 Java 类即可。

所有的这些信息用户在创建表的时候都可以在表定义语句中进行指定。创建完成后，用户可以像平时一样查询表，而无需关心底层格式。因此，如果用户是 Hive 的使用者，而不是 Java 工程师，就无需关心关于 Java 的信息。如果需要，用户所在团队的工程师可以帮忙指定需要的定义信息，而之后就可以像之前一样工作了。

11.3 开启中间压缩

对中间数据进行压缩可以减少 job 中 map 和 reduce task 间的数据传输量。对于中间数据压缩，选择一个低 CPU 开销的编/解码器要比选择一个压缩率高的编/解码器要重要得多。属性 `hive.exec.compress.intermediate` 的默认值是 `false`，如果要开启中间压缩，就需要将这个属性值修改为默认值为 `true`：

```
<property>
  <name>hive.exec.compress.intermediate</name>
  <value>true</value>
  <description> This controls whether intermediate files produced by Hive between
  multiple map-reduce jobs are compressed. The compression codec and other options
  are determined from hadoop config variables mapred.output.compress*
</description>
</property>
```



提示

对于其他Hadoop job来说控制中间数据压缩的属性是 `mapred.compress.map.output`。

Hadoop压缩默认的编/解码器是DefaultCodec。可以通过修改属性 `mapred.map.output.compression.codec` 的值来修改编/解码器。这是一个Hadoop配置项，可以在\$HADOOP_HOME/conf/mapred-site.xml文件中或\$HADOOP_HOME/conf/hive-site.xml文件中进行配置。SnappyCodec是一个比较好的中间文件压缩编/解码器，因为其很好地结合了低CPU开销和好的压缩执行效率：

```
<property>
  <name>mapred.map.output.compression.codec</name>
  <value>org.apache.hadoop.io.compress.SnappyCodec</value>
  <description> This controls whether intermediate files produced by Hive
  between multiple map-reduce jobs are compressed. The compression codec
  and other options are determined from hadoop config variables
  mapred.output.compress* </description>
</property>
```

11.4 最终输出结果压缩

当Hive将输出写入到表中时，输出内容同样可以进行压缩。属性 `hive.exec.compress.output` 控制着这个功能。用户可能需要保持默认配置文件中的默认值 `false`，这样默认的输出就是非压缩的纯文本文件了。用户可以通过在查询语句或执行脚本中设置这个值为 `true`，来开启输出结果压缩功能：

```
<property>
  <name>hive.exec.compress.output</name>
  <value>false</value>
  <description> This controls whether the final outputs of a query
  (to a local/hdfs file or a Hive table) is compressed. The compression
  codec and other options are determined from hadoop config variables
  mapred.output.compress* </description>
</property>
```



提示

对于其他Hadoop任务，开启最终输出结果压缩功能的属性是 `mapred.output.compress`。

如果属性 `hive.exec.compress.output` 的值设置为 `true`，那么这时需要为其指定一个编解码器。对于输出文件，使用 `GZip` 进行压缩是个不错的主意，因为其通常可以大幅度降低文件的大小。但是，需要记住的是 `GZip` 压缩的文件对于后面的 `MapReduce job` 而言是不可分割的。

```
<property>
  <name>mapred.output.compression.codec</name>
  <value>org.apache.hadoop.io.compress.GzipCodec</value>
  <description>If the job outputs are compressed, how should they be compressed?
  </description>
</property>
```

11.5 sequence file存储格式

压缩文件确实能够节约存储空间，但是，在Hadoop中存储裸压缩文件的一个缺点就是，通常这些文件是不可分割的。可分割的文件可以划分成多个部分，由多个 `mapper` 并行进行处理。大多数的压缩文件是不可分割的，也就是说只能从头读到尾。

Hadoop所支持的sequence file存储格式可以将一个文件划分成多个块，然后采用一种可分割的方式对块进行压缩。

如果想在Hive中使用sequence file存储格式，那么需要在CREATE TABLE语句中通过STORED AS SEQUENCEFILE语句进行指定：

```
CREATE TABLE a_sequence_file_table STORED AS SEQUENCEFILE;
```

Sequence file提供了3种压缩方式：NONE、RECORD和BLOCK，默认是RECORD级别（也就是记录级别）。不过，通常来说，BLOCK级别（也就是块级别）压缩性能最好而且是可以分割的。和很多其他的压缩属性一样，这个属性也并非是Hive特有的。用户可以在Hadoop

的mapred-site.xml文件中进行定义，或者在Hive的hive-site.xml文件中进行定义，需要的时候，还可以在脚本中或查询语句前进行指定：

```
<property>
  <name>mapred.output.compression.type</name>
  <value>BLOCK</value>
  <description>If the job outputs are to compressed as SequenceFiles,
  how should they be compressed? Should be one of NONE, RECORD or BLOCK.
  </description>
</property>
```

11.6 使用压缩实践

我们已经介绍了Hive中可以使用的一些压缩相关的配置属性，这些属性的不同组合方式将会产生不同的输出。下面，让我们在一些例子中使用这些属性，然后展示下它们的输出将会是什么。需要注意的是，CLI中通过set命令设置的属性在同一个会话中会一直生效的。因此，同一个会话中的不同例子间应该注意将设置复原，或者直接重开启一个Hive会话：

```
hive> SELECT * FROM a;
4      5
3      2
hive> DESCRIBE a;
a      int
b      int
```

首先，我们先开启中间数据压缩功能。这将不会影响到最终输出结果。不过从job的计数器信息上看，可以发现这个job中间传送的数据量变小了，因为shuffle sort(混洗排序)数据被压缩了：

```
hive> set hive.exec.compress.intermediate=true;
hive> CREATE TABLE intermediate_comp_on
  > ROW FORMAT DELIMITED FIELDS TERMINATED BY '\t'
  > AS SELECT * FROM a;
Moving data to: file:/user/hive/warehouse/intermediate_comp_on
Table default.intermediate_comp_on stats: [num_partitions: 0, num_files: 1,
num_rows: 2, total_size: 8, raw_data_size: 6]
...
```

和预期的一样，中间数据压缩没有影响到最终的输出，最终的数据结果仍然是非压缩的：

```

hive> dfs -ls /user/hive/warehouse/intermediate_comp_on;
Found 1 items
/user/hive/warehouse/intermediate_comp_on/000000_0

hive> dfs -cat /user/hive/warehouse/intermediate_comp_on/000000_0;
4      5
3      2

```

我们同样可以为中间数据压缩配置其他的编/解码器而不使用默认的编/解码器。下面这个例子，我们选择使用**GZip**（尽管通常**Snappy**是更好的选择）。为显示清晰，将下面语句中的第1行分成了2行：

```

hive> set mapred.map.output.compression.codec
      =org.apache.hadoop.io.compress.GZipCodec;
hive> set hive.exec.compress.intermediate=true;

hive> CREATE TABLE intermediate_comp_on_gz
      > ROW FORMAT DELIMITED FIELDS TERMINATED BY '\t'
      > AS SELECT * FROM a;
Moving data to: file:/user/hive/warehouse/intermediate_comp_on_gz
Table default.intermediate_comp_on_gz stats:
[num_partitions: 0, num_files: 1, num_rows: 2, total_size: 8, raw_data_size:6]

hive> dfs -cat /user/hive/warehouse/intermediate_comp_on_gz/000000_0;
4      5
3      2

```

下一步，我们可以开启输出结果压缩：

```

hive> set hive.exec.compress.output=true;

hive> CREATE TABLE final_comp_on
      > ROW FORMAT DELIMITED FIELDS TERMINATED BY '\t'
      > AS SELECT * FROM a;
Moving data to: file:/tmp/hive-edward/hive_2012-01-15_11-11-01_884_.../-ext-10001
Moving data to: file:/user/hive/warehouse/final_comp_on
Table default.final_comp_on stats:
[num_partitions: 0, num_files: 1, num_rows: 2, total_size: 16, raw_data_size:6]

hive> dfs -ls /user/hive/warehouse/final_comp_on;
Found 1 items
/user/hive/warehouse/final_comp_on/000000_0.deflate

```

输出信息中的表统计信息显示**total_size**（总大小）是16B，但是**raw_data_size**（裸数据）是6B，多出的存储空间是被**deflate**算法消耗了。同时我们可以看到，输出的文件后缀名是**.deflate**。

不推荐使用**cat**命令来查看这个压缩文件，因为用户只能看到二进制输出。不过，Hive可以正常地查询这个数据：

```
hive> dfs -cat /user/hive/warehouse/final_comp_on/000000_0.deflate;
... UGLYBINARYHERE ...

hive> SELECT * FROM final_comp_on;
4      5
3      2
```

这种无缝的处理压缩文件的能力并非是Hive独有的，实际上，这里是使用了Hadoop的TextInputFormat进行的处理。尽管在这种情况下这个命名有些令人混淆，但是TextInputFormat可以识别文件后缀名为.deflate或.gz的压缩文件，并且可以很轻松地进行处理。Hive无需关心底层的文件是否是压缩的，以及是使用何种压缩方案进行压缩的。

下面我们改变下输出结果压缩所使用的编解码器，然后看下结果（这里语句的第2行为了显示清晰，也分成2行了）：

```
hive> set hive.exec.compress.output=true;
hive> set mapred.output.compression.codec
      =org.apache.hadoop.io.compress.GzipCodec;
hive> CREATE TABLE final_comp_on_gz
      > ROW FORMAT DELIMITED FIELDS TERMINATED BY '\t'
      > AS SELECT * FROM a;
Moving data to: file:/user/hive/warehouse/final_comp_on_gz
Table default.final_comp_on_gz stats:
[num_partitions: 0, num_files: 1, num_rows: 2, total_size: 28, raw_data_size:6]

hive> dfs -ls /user/hive/warehouse/final_comp_on_gz;
Found 1 items
/user/hive/warehouse/final_comp_on_gz/000000_0.gz
```

正如用户可以看到的，输出文件夹下现在包含了零个或多个.gz文件。Hive提供了在Hive shell中执行像zcat这样的本地命令的快速方法。通过!符号，Hive可以执行外部的命令，直到返回结果。

zcat是一个命令行实用程序，用来解压缩，并进行输出显示：

```
hive> ! /bin/zcat /user/hive/warehouse/final_comp_on_gz/000000_0.gz;
4      5
3      2
hive> SELECT * FROM final_comp_on_gz;
OK
4      5
3      2
Time taken: 0.159 seconds
```

使用这种输出压缩能够完成那种很小，操作起来很快的文件的二进制压缩。不过，回想一下，输出文件的个数是和处理数据所需要的

mapper个数或reducers个数有关的。在最坏的情况下，可能最终结果是文件夹中只产生了一个大的压缩文件，而且是不可分割的。这意味着后续步骤并不能并行地处理这个数据。解决这个问题的答案就是使用sequence file：

```
hive> set mapred.output.compression.type=BLOCK;
hive> set hive.exec.compress.output=true;
hive> set mapred.output.compression.codec=org.apache.hadoop.io.compress.GzipCodec;

hive> CREATE TABLE final_comp_on_gz_seq
> ROW FORMAT DELIMITED FIELDS TERMINATED BY '\t'
> STORED AS SEQUENCEFILE
> AS SELECT * FROM a;
Moving data to: file:/user/hive/warehouse/final_comp_on_gz_seq
Table default.final_comp_on_gz_seq stats:
[num_partitions: 0, num_files: 1, num_rows: 2, total_size: 199, raw_data_size: 6]

hive> dfs -ls /user/hive/warehouse/final_comp_on_gz_seq;
Found 1 items
/user/hive/warehouse/final_comp_on_gz_seq/000000_0
```

Sequence file是二进制格式的，但是，我们可以很容易地查询文件头。通过查看文件头可以确认结果是否是我们需要的（为方便显示，输出格式进行了调整）：

```
hive> dfs -cat /user/hive/warehouse/final_comp_on_gz_seq/000000_0;
SEQ[]org.apache.hadoop.io.BytesWritable[]org.apache.hadoop.io.BytesWritable[]
org.apache.hadoop.io.compress.GzipCodec[]
```

因为sequence file中嵌入的元数据信息以及Hive元数据信息，Hive无需任何特别的设置就可以查询这张表。Hadoop同样提供了dfs -text命令来从sequence file文件中去除掉文件头和压缩，然后显示裸数据：

```
hive> dfs -text /user/hive/warehouse/final_comp_on_gz_seq/000000_0;
4      5
3      2
hive> select * from final_comp_on_gz_seq;
OK
4      5
3      2
```

最后，我们来同时使用直接数据压缩和最终输出数据压缩，而且使用不同压缩编/解码器的sequence file！这些设置通常应用在生产环境，这些环境中的数据集很大，而这些设置可以提高其性能：

```
hive> set mapred.map.output.compression.codec
=org.apache.hadoop.io.compress.SnappyCodec;
```

```
hive> set hive.exec.compress.intermediate=true;
hive> set mapred.output.compression.type=BLOCK;
hive> set hive.exec.compress.output=true;
hive> set mapred.output.compression.codec
=org.apache.hadoop.io.compress.GzipCodec;

hive> CREATE TABLE final_comp_on_gz_int_compress_snappy_seq
> ROW FORMAT DELIMITED FIELDS TERMINATED BY '\t'
> STORED AS SEQUENCEFILE AS SELECT * FROM a;
```

11.7 存档分区

Hadoop中有一种存储格式名为HAR，也就是Hadoop Archive（Hadoop归档文件）的简写。一个HAR文件就像在HDFS文件系统中的一个TAR文件一样是一个单独的文件。不过，其内部可以存放多个文件和文件夹。在一些使用场景下，较旧的文件夹和文件比较新的文件夹和文件被访问的概率要低很多。如果某个特定的分区下保存的文件有成千上万的话，那么就需要HDFS中的NameNode消耗非常大的代价来管理这些文件。通过将分区下的文件归档成一个巨大的，但是同时可以被Hive访问的文件，可以减轻NameNode的压力。不过其缺点是，HAR文件查询效率不高；同时，HAR文件并非是压缩的，因此也不会节约存储空间。

在下面的例子中，我们将使用Hive自带的文件作为表数据。

首先，创建一个分区表，然后将Hive包中自带的文件加载到表中：

```
hive> CREATE TABLE hive_text (line STRING) PARTITIONED BY (folder STRING);

hive> ! ls $HIVE_HOME;
LICENSE
README.txt
RELEASE_NOTES.txt

hive> ALTER TABLE hive_text ADD PARTITION (folder='docs');

hive> LOAD DATA INPATH '${env:HIVE_HOME}/README.txt'
> INTO TABLE hive_text PARTITION (folder='docs');
Loading data to table default.hive_text partition (folder=docs)

hive> LOAD DATA INPATH '${env:HIVE_HOME}/RELEASE_NOTES.txt'
> INTO TABLE hive_text PARTITION (folder='docs');
Loading data to table default.hive_text partition (folder=docs)

hive> SELECT * FROM hive_text WHERE line LIKE '%hive%' LIMIT 2;
http://hive.apache.org/    docs
- Hive 0.8.0 ignores the hive-default.xml file, though we continue    docs
```

某些Hadoop版本（例如Hadoop v0.20.2版本）要求包含Hadoop归档工具接口的JAR包要放置在Hive的auxlib路径下：

```
$ mkdir $HIVE_HOME/auxlib
$ cp $HADOOP_HOME/hadoop-0.20.2-tools.jar $HIVE_HOME/auxlib/
```

在归档之前，我们来看下这个表下面的底层目录结构。需要注意的是，表下面的数据是存储在分区目录下的，因为这是一个管理分区表：

```
hive> dfs -ls /user/hive/warehouse/hive_text/folder=docs;
Found 2 items
/usr/hive/warehouse/hive_text/folder=docs/README.txt
/usr/hive/warehouse/hive_text/folder=docs/RELEASE_NOTES.txt
```

ALTER TABLE ... ARCHIVE PARTITION语句将表转化成了一个归档表：

```
hive> SET hive.archive.enabled=true;
hive> ALTER TABLE hive_text ARCHIVE PARTITION (folder='docs');
intermediate.archived is
  file:/user/hive/warehouse/hive_text/folder=docs_INTERMEDIATE_ARCHIVED
intermediate.original is
  file:/user/hive/warehouse/hive_text/folder=docs_INTERMEDIATE_ORIGINAL
Creating data.har for file:/user/hive/warehouse/hive_text/folder=docs
in file:/tmp/hive-edward/hive_..._3862901820512961909/-ext-10000/partlevel
Please wait... (this may take a while)
Moving file:/tmp/hive-edward/hive_..._3862901820512961909/-ext-10000/partlevel
to file:/user/hive/warehouse/hive_text/folder=docs_INTERMEDIATE_ARCHIVED
Moving file:/user/hive/warehouse/hive_text/folder=docs
to file:/user/hive/warehouse/hive_text/folder=docs_INTERMEDIATE_ORIGINAL
Moving file:/user/hive/warehouse/hive_text/folder=docs_INTERMEDIATE_ARCHIVED
to file:/user/hive/warehouse/hive_text/folder=docs
```

（对于上面的输出，为便于展示，我们对其格式进行了调整，并使用...替换掉输出中的时间戳。）

下面这张表中由之前的两个文件变成了现在的一个Hadoop归档文件（也就是HAR文件）：

```
hive> dfs -ls /user/hive/warehouse/hive_text/folder=docs;
Found 1 items
/usr/hive/warehouse/hive_text/folder=docs/data.har
```

ALTER TABLE ... UNARCHIVE PARTITION命令可以将HAR中的文件提取出来然后重新放置到HDFS中:

```
ALTER TABLE hive_text UNARCHIVE PARTITION (folder='docs');
```

11.8 压缩: 包扎

Hive可以读和写不同类型的压缩文件, 确实可以获取很大的性能提升, 因为其可以节约磁存储空间以及处理开销。这种灵活性同样也有助于和其他工具进行集成, 因为Hive无需使用Java编写的自定义的“适配器”就可以查询很多本地文件类型。

[1]See <http://code.google.com/p/hadoop-snappy/>).

[2]See <http://wiki.apache.org/hadoop/UsingLzoCompression>).

第12章 开发

Hive不可能满足用户的所有需求，有时一个第三方的库可以填补这个空白。而其他情况下，用户或其他本身是Java开发工程师的人员可能需要开发一些用户自定义函数（也就是UDF，参考第13章的介绍）、序列化/反序列化器（也就是SerDe，参考第15.4节“记录格式：SerDe”）、输入或者输出文件格式（参考第15章中的介绍）或者其他一些增强功能。

本章将探讨Hive自身的源代码，其中包括Hive v0.8.0版本中新增的开发工具包插件（也就是PDK）。

12.1 修改Log4J属性

Hive可以通过\$HIVE_HOME/conf目录下的2个Log4J配置文件来配置日志。其中hive-log4j.properties文件用来控制CLI和其他本地执行组件的日志；而hive-exec-log4j.properties文件用来控制MapReduce task内的日志，这个文件并非必须在Hive安装目录下存在，因为Hive JAR包中已经包含了默认属性值。事实上，conf目录下的文件是带有.template文件扩展名的，因此默认是不会被加载的。如果想使用这2个配置，只需要将.template扩展名去掉，然后按需要进行修改就可以了：

```
$ cp conf/hive-log4j.properties.template conf/hive-log4j.properties
$ ... edit file ...
```

也可以临时地改变日志配置而无需拷贝和修改Log4J文件。在Hive Shell启动时可以通过hiveconf参数指定log4j.properties文件中的任意属性。例如，下面的语句指定输出日志为DEBUG级别，而且输出到控制台中：

```
$ bin/hive -hiveconf hive.root.logger=DEBUG,console
12/03/27 08:46:01 WARN conf.HiveConf: hive-site.xml not found on CLASSPATH
12/03/27 08:46:01 DEBUG conf.Configuration: java.io.IOException: config()
```

12.2 连接Java调试器到Hive

当开启详细输出也无法帮助找到解决问题的办法时，可以通过附加一个Java调试器，对Hive代码进行单步调试，来找到问题所在。

远程调试是Java提供的一个功能，其可以通过命令行对JVM指定参数后进行启动。Hive Shell脚本提供了一个开关和控制台帮助信息帮助用户方便地设置这些属性（为了便于页面展示，下面输出信息中有部分信息省略掉了）：

```
$ bin/hive --help --debug
Allows to debug Hive by connecting to it via JDI API
Usage: hive --debug[:comma-separated parameters list]

Parameters:

recursive=<y|n>      Should child JVMs also be started in debug mode. Default:y
port=<port_number>   Port on which main JVM listens for debug connection. Default...
mainSuspend=<y|n>    Should main JVM wait with execution for the debugger to con...
childSuspend=<y|n>   Should child JVMs wait with execution for the debugger to c...
swapSuspend           Swaps suspend options between main and child JVMs
```

12.3 从源码编译Hive

使用Apache的Hive发行版通常是个不错的选择，不过用户可能需要当前版本中没有提供的功能，或者使用的是一个非公开的自己定制的内部分支。

因此，用户将需要对Hive进行源码编译。编译Hive的最低要求是，需要一个较新版本的Java JDK、Subversion和ANT。Hive也包含了一些默认不会进行编译的组件，例如通过Thrift生成的一些类。如果期望对Hive完成重编译，那么还需要安装好Thrift编译器。

下面的系列命令分别是从svn中下载一份Hive发行版代码，然后对源码进行编译，编译后会在hive-trunk/build/dist目录下生成结果：

```
$ svn co http://svn.apache.org/repos/asf/hive/trunk hive-trunk
$ cd hive-trunk
$ ant package

$ ls build/dist/
bin examples LICENSE README.txt      scripts
conf lib          NOTICE    RELEASE_NOTES.txt
```

12.3.1 执行Hive测试用例

Hive本身有一个独特的内置的测试框架。Hive确实有传统的JUnit测试用例，不过主要的测试还是通过执行以.q结尾的文件，然后将执行结果和之前的执行结果文件[1]进行比对来进行的。在Hive源码目录下有很多的目录。其中，有“正面”的测试，也就是结果应该是正确的测试；还有“反面”的测试，也就是执行结果应该是失败的测试。

正面的测试是一个符合语法规则的查询，而负面的测试是一个不符合语法规则的或者尝试做一些HiveQL不允许做的操作：

```
$ ls -lah ql/src/test/queries/
total 76K
drwxrwxr-x. 7 edward edward 4.0K May 28 2011 .
drwxrwxr-x. 8 edward edward 4.0K May 28 2011 ..
drwxrwxr-x. 3 edward edward 20K Feb 21 20:08 clientnegative
drwxrwxr-x. 3 edward edward 36K Mar 8 09:17 clientpositive
drwxrwxr-x. 3 edward edward 4.0K May 28 2011 negative
drwxrwxr-x. 3 edward edward 4.0K Mar 12 09:25 positive
```

可以看一下ql/src/test/queries/clientpositive/cast1.q这个文件。用户需要知道的是，在测试过程中会首先自动创建一张名为src的表。表src具有2个字段，也就是INT类型的字段key和STRING类型的字段value。因为Hive目前还不支持没有FROM语句的SELECT查询，所以对于一些函数的测试有一个技巧，那就是通过“硬编码”函数的输入进行测试，而无需真正访问表中的数据。

正如用户在下面的例子中所看到的，在SELECT语句中，src表中的数据永远没有使用到：

```
hive> CREATE TABLE dest1(c1 INT, c2 DOUBLE, c3 DOUBLE,
> c4 DOUBLE, c5 INT, c6 STRING, c7 INT) STORED AS TEXTFILE;

hive> EXPLAIN
> FROM src INSERT OVERWRITE TABLE dest1
> SELECT 3 + 2, 3.0 + 2, 3 + 2.0, 3.0 + 2.0,
> 3 + CAST(2.0 AS INT) + CAST(CAST(0 AS SMALLINT) AS INT),
> CAST(1 AS BOOLEAN), CAST(TRUE AS INT) WHERE src.key = 86;

hive> FROM src INSERT OVERWRITE TABLE dest1
> SELECT 3 + 2, 3.0 + 2, 3 + 2.0, 3.0 + 2.0,
> 3 + CAST(2.0 AS INT) + CAST(CAST(0 AS SMALLINT) AS INT),
> CAST(1 AS BOOLEAN), CAST(TRUE AS INT) WHERE src.key = 86;

hive> SELECT dest1.* FROM dest1;
```

上面这个脚本的输出可以在ql/src/test/results/clientpositive/cast1.q.out这个文件中找到。这个输出结

果文件太大了，如果这里展示完整的结果的话，就太浪费纸张了。不过，增加这个文件也没有价值。

如下命令展示的是Hive客户端分别执行一个正面的测试用例和一个负面的测试用例：

```
ant test -Dtestcase=TestCliDriver -Dqfile=mapreduce1.q
ant test -Dtestcase=TestNegativeCliDriver -Dqfile=script_broken_pipe1.q
```

上面两个测试仅仅是解析了查询语句，它们实际上并没有在客户端执行。现在它们已经被启用了，而推荐使用clientpositive和clientnegative来区分了。

用户同样可以在一次ant调用过程中执行多个测试脚本，这样可以节约时间（注意下面-Dqfile=...后面的字符串是一个完整的字符串，展示在多行是为了便于排版）：

```
ant test -Dtestcase=TestCliDriver -Dqfile=avro_change_schema.q,avro_joins.q,
avro_schema_error_message.q,avro_evolved_schemas.q,avro_sanity_test.q,
avro_schema_literal.q
```

12.3.2 执行hook

前置hook和后置hook是允许用户进行hook编码，然后在Hive中进行编译并执行自定义代码的实用工具。Hive的测试框架就使用了hook来执行不会产生输出的命令，因此结果只会在测试内部出现：

```
PREHOOK: query: CREATE TABLE dest1(c1 INT, c2 DOUBLE, c3 DOUBLE,
c4 DOUBLE, c5 INT, c6 STRING, c7 INT) STORED AS TEXTFILE
PREHOOK: type: CREATETABLE
POSTHOOK: query: CREATE TABLE dest1(c1 INT, c2 DOUBLE, c3 DOUBLE,
c4 DOUBLE, c5 INT, c6 STRING, c7 INT) STORED AS TEXTFILE
```

12.4 配置Hive和Eclipse

Eclipse是一个开源的IDE（集成开发环境）。通过如下操作可以让Hive代码在Eclipse中使用：

```
$ ant clean package eclipse-files
$ cd metastore
$ ant model-jar
```

```
$ cd ../../ql  
$ ant gen-test
```

一旦编译后，用户就可以将工程导入到Eclipse中，然后按通常使用的方式使用就可以了。

按常规方式，首先在Eclipse中创建一个工作空间（workspace），然后使用File（文件）→Import（导入）命令，再选择General（常规）→Existing Projects into Workspace（导入已经存在的工程到工作空间中），最后选择Hive源码所在的目录即可。

当出现向导中列举的系列工程名称时，应该可以看到其中有一个是名为hive-trunk的工程，用户只需要选择这个工程然后按Finish（完成）就可以了。

图12-1展示了如何在Eclipse中启动Hive命令行CLI驱动器。




图12-1 在Eclipse中启动Hive命令行CLI驱动器

12.5 Maven工程中使用Hive

用户可以在Maven编译中设置Hive为依赖包。Maven资源库 <http://mvnrepository.com/artifact/org.apache.hive/hive-service> 中包含了最新的发行版。

这个页面里同样列出了hive-service所需要的依赖包。

下面是Hive v0.9.0版本的顶级依赖关系定义，这里没有包含与之相关的依赖树，因为实在太多了：

```
<dependency>
  <groupId>org.apache.hive</groupId>
  <artifactId>hive-service</artifactId>
  <version>0.9.0</version>
</dependency>
```

为我们后面将讲到的hive_test准备的pom.xml文件包含了Hive v0.9.0版本完整的依赖树关系。用户可以通过如下链接查看这个文件：https://github.com/edwardcapriolo/hive_test/blob/master/pom.xml。

12.6 Hive中使用hive_test进行单元测试

还有一种使用Hive的方式就是利用Thrift通过HiveService来访问Hive，然后写一些应用。不过，因为Hive需要众多的JAR依赖以及元数据模块，Thrift服务通常难以在嵌入式的环境中使用。

hive_test从Maven中获取到所有的Hive依赖，并且在本地建立起元数据和Thrift服务，然后提供测试类来让单元测试更加简单。同时，因为其是非常轻量级的，所以单元测试执行得很快。当然，这是相对于在Hive中通过test模块进行测试而言的，因为后者需要重编译整个工程，然后才能执行某个单元测试。

hive_test是测试如UDF、输入格式、SerDe或其他作为HiveQL语言插件的模块代码的理想方式。不过这个无助于内部的Hive开发，因为所有的Hive组件都是从Maven中拖下来的，而且都是属于工程之外的。

在Maven工程中，创建一个pom.xml文件，然后按如下的方式将hive_test作为依赖项加入：

```
<dependency>
  <groupId>com.jointhegrid</groupId>
  <artifactId>hive_test</artifactId>
  <version>3.0.1-SNAPSHOT</version>
</dependency>
```

然后创建一个hive-site.xml文件：

```
$ cp $HIVE_HOME/conf/* src/test/resources/
$ vi src/test/resources/hive-site.xml
```

和常规的hive-site.xml文件不同的是，这个版本的配置文件不应该保存任何数据到一个永久的地方。这是因为单元测试并不应该创建或保存任何永久的状态。将javax.jdo.option.ConnectionURL这个属性设置为使用Derby作为数据库，这样就只会将数据库保存在主内存中。数据仓库目录hive.metastore.warehouse.dir设置为/tmp下的某个目录，这样每次执行的单元测试都会被删除掉：

```
<configuration>

<property>
  <name>javax.jdo.option.ConnectionURL</name>
  <value>jdbc:derby:memory:metastore_db;create=true</value>
  <description>JDBC connect string for a JDBC metastore</description>
</property>

<property>
  <name>hive.metastore.warehouse.dir</name>
  <value>/tmp/warehouse</value>
  <description>location of default database for the warehouse</description>
</property>

</configuration>
```

hive_test提供了多个扩展了JUnit测试用例的类。HiveTestService会先初始化好环境，清空数据仓库目录，然后会在进程中启动元数据服务和HiveService。其通常是扩展测试的组件。不过，其他组件（例如HiveTestEmbedded）同样是可使用的：

```
package com.jointhegrid.hive_test;
import java.io.BufferedWriter;
import java.io.IOException;
import java.io.OutputStreamWriter;

import org.apache.hadoop.fs.FSDataOutputStream;
import org.apache.hadoop.fs.Path;

/* Extending HiveTestService creates and initializes
the metastore and thrift service in an embedded mode */
public class ServiceHiveTest extends HiveTestService {

    public ServiceHiveTest() throws IOException {
        super();
    }

    public void testExecute() throws Exception {
        /* Use the Hadoop filesystem API to create a
        data file */
        Path p = new Path(this.ROOT_DIR, "afile");
        FSDataOutputStream o = this.getFileSystem().create(p);
        BufferedWriter bw = new BufferedWriter(new OutputStreamWriter(o));
        bw.write("1\\n");
    }
}
```

```
        bw.write("2\n");
        bw.close();

        /* ServiceHive is a component that connects
        to an embedded or network HiveService based
        on the constructor used */
        ServiceHive sh = new ServiceHive();

        /* We can now interact through the HiveService
        and assert on results */
        sh.client.execute("create table atest (num int)");
        sh.client.execute("load data local inpath '"
            + p.toString() + "' into table atest");
        sh.client.execute("select count(1) as cnt from atest");
        String row = sh.client.fetchOne();
        assertEquals("2", row);
        sh.client.execute("drop table atest");
    }
}
```

12.7 新增的插件开发工具箱（PDK）

Hive v0.8.0版本中新加了一个插件开发工具箱（PDK）。PDK的目的是允许开发者可以无需Hive源码，而仅仅需要二进制代码即可编译和测试插件。

PDK相对较新，而且其本身因为有一些棘手的bug，所以比较难用。如果不管怎样想尝试使用PDK的话，那么可以参考如下的wiki页面：<https://cwiki.apache.org/Hive/plugindeveloperkit.html>。不过要注意这个页面中也有一些错误，至少在写本书时还是存在一些错误的。

[1]也就是说，它们更像是功能或可用性测试。

第13章 函数

用户自定义函数（UDF）是一个允许用户扩展HiveQL的强大功能。正如我们将看到的，用户使用Java进行编码。一旦将用户自定义函数加入到用户会话中（交互式的或者通过脚本执行的），它们就将和内置的函数一样使用，甚至可以提供联机帮助。Hive具有多种类型的用户自定义函数，每一种都会针对输入数据执行特定“一类”的转换过程。

在ETL处理中，一个处理过程可能包含多个处理步骤。Hive语言具有多种方式来将上一步骤的输入通过管道传递给下一个步骤，然后在一个查询中产生众多输出。用户同样可以针对一些特定的处理过程编写自定义函数。如果没有这个功能，那么一个处理过程可能就需要包含一个MapReduce步骤或者需要将数据转移到另一个系统中来实现这些改变。互联系统增加了复杂性，并且增加了配置错误或其他错误的发生几率。当数据量是GB甚至TB级别时，在不同系统中转移数据，需要消耗大量的时间。与此相反，UDF是在Hive查询产生的相同的task进程中执行的，因此它们可以高效地执行，而且其消除了和其他系统集成时所产生的复杂度。本章涵括创建和使用UDF的最佳实践。

13.1 发现和描述函数

在编写自定义UDF之前，我们先来熟悉下Hive中自带的那些UDF。需要注意的是在Hive中通常使用“UDF”来表示任意的函数，包括用户自定义的或者内置的。

SHOW FUNCTIONS 命令可以列举出当前Hive会话中所加载的所有函数名称，其中包括内置的和用户加载进来的函数，加载方式稍后会进行介绍：

```
hive> SHOW FUNCTIONS;
abs
acos
and
array
```

```
array_contains
...
```

函数通常都有其自身的使用文档。使用DESCRIBE FUNCTION命令可以展示对应函数简短的介绍：

```
hive> DESCRIBE FUNCTION concat;
concat(str1, str2, ... strN) - returns the concatenation of str1, str2, ... strN
```

函数也可能包含更多的详细文档，可以通过增加EXTENDED关键字进行查看：

```
hive> DESCRIBE FUNCTION EXTENDED concat;
concat(str1, str2, ... strN) - returns the concatenation of str1, str2, ... strN
Returns NULL if any argument is NULL.
Example:
> SELECT concat('abc', 'def') FROM src LIMIT 1;
'abcdef'
```

13.2 调用函数

如果想使用函数，只需要在查询中通过调用函数名，并传入需要的参数即可。某些函数需要指定特定的参数个数和参数类型，而其他函数可以传入一组参数，参数类型可以是多样的。和关键字一样，函数名也是保留的字符串：

```
SELECT concat(column1,column2) AS x FROM table;
```

13.3 标准函数

用户自定义函数（英文缩写为UDF）这个术语在狭义的概念上还表示以一行数据中的一列或多列数据作为参数然后返回结果是一个值的函数。大多数函数都是属于这类的。

我们使用的例子中包含了很多的数学函数。例如round()和floor()，其可以将DOUBLE类型转换为BIGINT类型；还有abs()，这个函数可以返回数值的绝对值。

其他一些例子中还包含有字符串操作函数。例如ucase()，这个函数可以将字符串转换成全是大写字母的；reverse()函数，可以将字符

串进行反转；而concat()函数可以将输入的多个字符串拼接成一个字符串输出。

需要注意的是，这些UDF同样可以返回一个复杂的对象，例如array、map或者struct。

13.4 聚合函数

另一种函数是聚合函数。所有的聚合函数、用户自定义函数和内置函数，都统称为用户自定义聚合函数（UDAF）。

聚合函数接受从零行到多行的零个到多个列，然后返回单一值。这样的例子包括数学函数sum()，其返回所有输入求和后的值；avg()函数会计算所有输入的值的平均值；min()和max()函数，可以分别返回输入值中的最小值和最大值：

```
hive> SELECT avg(price_close)
> FROM stocks
> WHERE exchange = 'NASDAQ' AND symbol = 'AAPL';
```

聚合方法通常和GROUP BY语句组合使用。下面这个例子我们在第6.3节“GROUP BY语句”中使用过：

```
hive> SELECT year(ymd), avg(price_close) FROM stocks
> WHERE exchange = 'NASDAQ' AND symbol = 'AAPL'
> GROUP BY year(ymd);
1984    25.578625440597534
1985    20.193676221040867
1986    32.46102808021274
...
```

第6章中的表6-3中列举了可以在HiveQL中使用的所有内置聚合函数。

13.5 表生成函数

Hive所支持的第3类函数就是表生成函数。和其他函数类别一样，所有的表生成函数，包括用户自定义的和内置的，都统称为用户自定义表生成函数（UDTF）。

表生成函数接受零个或多个输入，然后产生多列或多行输出。例如，array函数就是将一列输入转换成一个数组输出的。下面的查询语句中使用了array函数：

```
hive> SELECT array(1,2,3) FROM dual;
[1,2,3]
```

explode()函数以array类型数据作为输入，然后对数组中的数据进行迭代，返回多行结果，一行一个数组元素值。

```
hive> SELECT explode(array(1,2,3)) AS element FROM src;
1
2
3
```

不过，Hive只允许表生成函数以特定的方式使用。例如，一个显著的限制就是，我们无法从表中产生其他的列。例13-1所示的这个查询可能是前面我们对于employees表进行的操作。我们可能需要列举出每名雇员的下属员工：

例13-1 explode函数的错误使用方式：

```
hive> SELECT name, explode(subordinates) FROM employees;
FAILED: Error in semantic analysis: UDTF's are not supported outside
the SELECT clause, nor nested in expressions
```

不过，Hive提供了一个LATERAL VIEW功能来实现这种查询：

```
hive> SELECT name, sub
>   FROM employees
>   LATERAL VIEW explode(subordinates) subView AS sub;
John Doe      Mary Smith
John Doe      Todd Jones
Mary Smith    Bill King
```

需要注意的是，对于职位不是经理的雇员（即没有下属员工的人）来说是没有输出行的，例如Bill King和Todd Jones就不会有对应的输出行。因此，输出中将会产生零到多行新纪录。

通过LATERAL VIEW可以方便地将explode这个UDTF得到的行转列的结果集合在一起提供服务。使用LATERAL VIEW需要指定视图别名和生成的新列的别名，对于本例，其分别是subView和sub。

第6章中的表6-4中列举了所有的内置的表生成行数。

13.6 一个通过日期计算其星座的UDF

下面我们开始编写自己的UDF。假设我们有一张表，表中的一个字段存储的是每个用户的生日。通过这个信息，我们期望能够计算出每个人所属的星座。

下面是一个样本数据集，我们将其放到用户根目录下一个名为littlebigdata.txt的文件中：

```
edward capriolo,edward@media6degrees.com,2-12-1981,209.191.139.200,M,10
bob,bob@test.net,10-10-2004,10.10.10.1,M,50
sara connor,sara@sky.net,4-5-1974,64.64.5.1,F,2
```

将样本数据载入到名为littlebigdata的表中：

```
hive > CREATE TABLE IF NOT EXISTS littlebigdata(
>   name      STRING,
>   email     STRING,
>   bday      STRING,
>   ip        STRING,
>   gender    STRING,
>   anum      INT)
> ROW FORMAT DELIMITED FIELDS TERMINATED BY ',';

hive> LOAD DATA LOCAL INPATH '${env:HOME}/littlebigdata.txt'
> INTO TABLE littlebigdata;
```

函数的输入将是一个日期，而函数输出将是表示该用户星座的字符串。

下面是我们期望的这个UDF的Java实现：

```
package org.apache.hadoop.hive.contrib.udf.example;

import java.util.Date;
import java.text.SimpleDateFormat;
import org.apache.hadoop.hive.ql.exec.UDF;

@Description(name = "zodiac",
  value = "_FUNC_(date) - from the input date string "+
  "or separate month and day arguments, returns the sign of the Zodiac.",
  extended = "Example:\n"+
  "+ \" > SELECT _FUNC_(date_string) FROM src;\n"+
  "+ \" > SELECT _FUNC_(month, day) FROM src;")
```

```

public class UDFZodiacSign extends UDF{

    private SimpleDateFormat df;

    public UDFZodiacSign(){
        df = new SimpleDateFormat("MM-dd-yyyy");
    }

    public String evaluate( Date bday ){
        return this.evaluate( bday.getMonth(), bday.getDay() );
    }

    public String evaluate(String bday){
        Date date = null;
        try {
            date = df.parse(bday);
        } catch (Exception ex) {
            return null;
        }
        return this.evaluate( date.getMonth()+1, date.getDay() );
    }

    public String evaluate( Integer month, Integer day ){
        if (month==1) {
            if (day < 20 ){
                return "Capricorn";
            } else {
                return "Aquarius";
            }
        }
        if (month==2){
            if (day < 19 ){
                return "Aquarius";
            } else {
                return "Pisces";
            }
        }
        /* ...other months here */
        return null;
    }
}

```

（译者注：这段代码有2个很明显的错误，其一，`bdy.getMonth`的返回值范围是0~11，其中值0表示一月份，因此这里面正确的写法应该是`bdy.getMonth+1`，其二`bdy.getDay()`返回的是一周中的第几天，显然不对，这里应该使用`bdy.getDate()`返回月中的天数。）

编写一个UDF，需要继承UDF类并实现evaluate()函数。在查询执行过程中，查询中对应的每个应用到这个函数的地方都会对这个类进行实例化。对于每行输入都会调用到evaluate()函数。而evaluate()处理

后的值会返回给Hive。同时用户是可以重载evaluate方法的。Hive会像Java的方法重载一样，自动选择匹配的方法。

代码中的@Description(...)表示的是Java总的注解，是可选的。注解中注明了关于这个函数的文档说明，用户需要通过这个注解来阐明自定义的UDF的使用方法和例子。这样当用户通过DESCRIBE FUNCTION ...命令查看该函数时，注解中的FUNC字符串将会被替换为用户为这个函数定义的“临时”函数名称，定义方式下面会进行介绍。



提示

UDF中evaluate()函数的参数和返回值类型只能是Hive可以序列化的数据类型。例如，如果用户处理的全是数值，那么UDF的输出参数类型可以是基本数据类型int、Integer封装的对象或者是一个IntWritable对象，也就是Hadoop对整型封装后的对象。用户不需要特别地关心将调用到哪个类型，因为当类型不一致的时候，Hive会自动将类型转换成匹配的类型。需要记住的是，null在Hive中对于任何数据类型都是合法的，但是对于Java基本数据类型，不能是对象，也不能是null。

如果想在Hive中使用UDF，那么需要将Java代码进行编译，然后将编译后的UDF二进制类文件打成一个JAR文件。然后，在Hive会话中，将这个JAR文件加入到类路径下，再通过CREATE FUNCTION语句定义好使用这个Java类的函数：

```
hive> ADD JAR /full/path/to/zodiac.jar;
hive> CREATE TEMPORARY FUNCTION zodiac
> AS 'org.apache.hadoop.hive.contrib.udf.example.UDFZodiacSign';
```

需要注意的是，JAR文件路径是不需要用引号括起来的，同时，到目前为止这个路径需要是当前文件系统的全路径。Hive不仅仅将这个JAR文件加入到classpath下，同时还将其加入了分布式缓存中，这样整个集群的机器都是可以获得该JAR文件的。

现在这个判断星座的UDF可以像其他的函数一样使用了。需要注意下CREATE FUNCTION语句中的TEMPORARY这个关键字。当前会

话中声明的函数只会在当前会话中有效。因此用户需要在每个会话中都增加JAR然后创建函数。不过，如果用户需要频繁地使用同一个JAR文件和函数的话，那么可以将相关语句增加到\$HOME/.hiverc文件中去：

```
hive> DESCRIBE FUNCTION zodiac;
zodiac(date) - from the input date string or separate month and day
arguments, returns the sign of the Zodiac.

hive> DESCRIBE FUNCTION EXTENDED zodiac;
zodiac(date) - from the input date string or separate month and day
arguments, returns the sign of the Zodiac.

Example:
> SELECT zodiac(date_string) FROM src;
> SELECT zodiac(month, day) FROM src;

hive> SELECT name, bday, zodiac(bday) FROM littlebigdata;
edward capriolo      2-12-1981      Aquarius
bob                  10-10-2004      Libra
sara connor          4-5-1974      Aries
```

再次说明下，UDF允许用户在Hive语言中执行自定义的转换过程。通过上面那个UDF，Hive现在可以通过用户生日计算得到相应的星座名称了，当然也可以做其他的聚合和转换过程。

当我们使用完自定义UDF后，我们可以通过如下命令删除此函数：

```
hive> DROP TEMPORARY FUNCTION IF EXISTS zodiac;
```

像通常一样，IF EXISTS是可选的。如果增加此关键字，则即使函数不存在也不会报错。

13.7 UDF与GenericUDF

前面介绍的那个计算星座的UDF例子中，我们继承的是UDF类。Hive还提供了一个对应的称为GenericUDF的类。GenericUDF是更为复杂的抽象概念，但是其支持更好的null值处理同时可以处理一些标准的UDF无法支持的编程操作。GenericUDF的一个例子就是Hive中的CASE ... WHEN语句，其会根据语句中输入的参数而产生复杂的处理逻辑。下面我们将展示如何通过继承GenericUDF类来编写一个用户自

定义函数，我们称之为nvl()，这个函数传入的值如果是null，那么就会返回一个默认值。

函数nvl()要求有2个参数。如果第1个参数是非null值，那么就会返回这个值；如果第1个参数是null，那么将返回第2参数的值。

GenericUDF框架正适合处理这类问题。通过继承标准的UDF确实是一个解决方案，不过那样就需要针对如此多的输入类型重载众多的evaluate方法，这样显得非常麻烦。而GenericUDF将会以编程的方式检查输入的数据类型，然后做出合适的反馈。

我们以普通import语句的细目列表开始这个代码：

```
package org.apache.hadoop.hive.ql.udf.generic;

import org.apache.hadoop.hive.ql.exec.Description;
import org.apache.hadoop.hive.ql.exec.UDFArgumentException;
import org.apache.hadoop.hive.ql.exec.UDFArgumentLengthException;
import org.apache.hadoop.hive.ql.exec.UDFArgumentTypeException;
import org.apache.hadoop.hive.ql.metadata.HiveException;
import org.apache.hadoop.hive.ql.udf.generic.GenericUDF;
import org.apache.hadoop.hive.ql.udf.generic.GenericUDFUtils;
import org.apache.hadoop.hive.serde2.objectinspector.ObjectInspector;
```

之后，我们使用@Description注解来为这个UDF写明使用文档：

```
@Description(name = "nvl",
value = "_FUNC_(value,default_value) - Returns default value if value"
+" is null else returns value",
extended = "Example:\n"
+ " > SELECT _FUNC_(null,'bla') FROM src LIMIT 1;\n")
```

现在需要这个类继承GenericUDF，然后开发这个类通常需要实现的方法。

其中initialize()方法会被输入的每个参数调用，并最终传入到一个ObjectInspector对象中。这个方法的目标是确定参数的返回类型。如果传入方法的类型是不合法的，这时用户同样可以向控制台抛出一个Exception异常信息。returnOIResolver是一个内置的类，其通过获取非null值的变量的类型并使用这个数据类型来确定返回值类型：

```
public class GenericUDFNvl extends GenericUDF {
  private GenericUDFUtils.ReturnObjectInspectorResolver returnOIResolver;
  private ObjectInspector[] argumentOIs;

  @Override
```

```

public ObjectInspector initialize(ObjectInspector[] arguments)
    throws UDFArgumentException {
    argumentOIs = arguments;
    if (arguments.length != 2) {
        throw new UDFArgumentLengthException(
            "The operator 'NVL' accepts 2 arguments.");
    }
    returnOIResolver = new GenericUDFUtils.ReturnObjectInspector.Resolver(true);
    if (!((returnOIResolver.update(arguments[0]) && returnOIResolver
        .update(arguments[1])))) {
        throw new UDFArgumentTypeException(2,
            "The 1st and 2nd args of function NVL should have the same type, "
            + "but they are different: '" + arguments[0].getTypeName()
            + "' and '" + arguments[1].getTypeName() + "'");
    }
    return returnOIResolver.get();
}
...

```

方法evaluate的输入是一个DeferredObject对象数组，而initialize方法中创建的returnOIResolver对象就用于从DeferredObjects对象中获取到值。在这种情况下，这个函数将会返回第1个非null值：

```

...
@Override
public Object evaluate(DeferredObject[] arguments) throws HiveException {
    Object retVal = returnOIResolver.convertIfNecessary(arguments[0].get(),
        argumentOIs[0]);
    if (retVal == null ){
        retVal = returnOIResolver.convertIfNecessary(arguments[1].get(),
            argumentOIs[1]);
    }
    return retVal;
}
...

```

最后一个要实现的方法就是getDisplayString ()，其用于Hadoop task内部，在使用到这个函数时来展示调试信息：

```

...
@Override
public String getDisplayString(String[] children) {
    StringBuilder sb = new StringBuilder();
    sb.append("if ");
    sb.append(children[0]);
    sb.append(" is null ");
    sb.append("returns");
    sb.append(children[1]);
    return sb.toString();
}

```

为了展示这个UDF的通用处理特性，下面的查询中对其调用了多次，每次都传入不同类型的参数，正如下面例子所展示的：

```
hive> ADD JAR /path/to/jar.jar;
hive> CREATE TEMPORARY FUNCTION nvl
> AS 'org.apache.hadoop.hive.ql.udf.generic.GenericUDFNvl';
hive> SELECT nvl( 1 , 2 ) AS COL1,
>          nvl( NULL, 5 ) AS COL2,
>          nvl( NULL, "STUFF" ) AS COL3
> FROM src LIMIT 1;
1      5      STUFF
```

13.8 不变函数

到目前为止我们都是将代码打包成JAR文件，然后再使用ADD JAR和CREATE TEMPORARY FUNCTION命令来使用这些函数的。

用户同样可以将自己的函数永久地加入到Hive中，不过这就需要对Hive的Java文件进行简单的修改，然后重新编译Hive。

对于Hive源代码，需要对
ql/src/java/org/apache/hadoop/hive/ql/exec/FunctionRegistry.java这个
FunctionRegistry类进行一行的代码修改。然后按照Hive源码分支的编
译方式，对Hive源码重新编译即可。

尽管建议是重新部署整个新的编译后的版本，不过实际上只需要
替换hive-exec-*.jar这个JAR文件即可，其中*表示的是版本号，需要
替换成具体的值。

下面就是一个将nvl()函数增加到Hive内置函数列表中时对于
FunctionRegistry类的修改方式：

```
...
registerUDF("parse_url", UDFParseUrl.class, false);
registerGenericUDF("nvl", GenericUDFNvl.class);
registerGenericUDF("split", GenericUDFSplit.class);
...
```

13.9 用户自定义聚合函数

用户同样可以定义聚合函数，不过，接口实现起来比较复杂。聚合函数会分多个阶段进行处理。基于UDAF执行的转换的不同，在不同阶段的返回值类型也可能是不同的。例如，`sum()`这个UDAF可以接受基本数据类型中的整型输入，然后创建整型部分数据，最终产生一个整型结果；而`median()`这个聚合函数会接受整型输入，然后中间会产生一组整型部分数据，最后产生一个整型结果。

作为通用的用户自定义聚合函数的例子，可以查看<http://svn.apache.org/repos/asf/hive/branches/branch-0.8/ql/src/java/org/apache/hadoop/hive/ql/udf/generic/GenericUDAAverage.java>这个`GenericUDAAverage`类的源代码。



提示

聚合过程是在`map`或者`reduce`任务（task）中执行的，其是一个有内存限制的Java进程。因此，在聚合过程中存储大的结构化数据可能会产生内存溢出错误。对于`min()`这个UDAF而言，只需要在内存中保存单个元素来进行比较即可。而`collectset()`这个UDAF内部是使用`set`来排重存储数据，以减少内存使用量的。`percentile_approx()`使用近似算法来获取近似结果以限制内存使用。在写UDAF的时候一定要注意内存使用的问题。通过配置参数`mapred.child.java.opts`可以调整执行过程的内存需求量，但是这种方式并非总是奏效。

```
<property>
  <name>mapred.child.java.opts</name>
  <value>-Xmx200m</value>
</property>
```

创建一个COLLECT UDAF来模拟GROUP_CONCAT

MySQL中有一个非常有用的函数名为`GROUP_CONCAT`，其可以将一组中的所有元素按照用户指定的分隔符组装成一个字符串。下面这个例子展示了MySQL中是如何使用这个函数的：

```
mysql > CREATE TABLE people (
  name STRING,
  friendname STRING );
```

```

mysql > SELECT * FROM people;
bob      sara
bob      john
bob      ted
john     sara
ted      bob
ted      sara

mysql > SELECT name, GROUP_CONCAT(friendname SEPARATOR ',')
      FROM people
      GROUP BY name;
bob      sara,john,ted
john     sara
ted      bob,sara

```

我们无需增加新的语法就可以在Hive中实现同样的转换。首先，我们需要一个聚合函数将所有的输入作为一个列表加入到集合中。Hive中已经有了一个叫做collect_set的UDAF来将所有的输入加入到一个java.util.Set集合中。Set类型的集合会在插入输入的时候自动进行排重，这对于GROUP CONCAT来说是不合适的。为了组装合适的集合，我们使用collect_set中的代码来将Set的实例替换成ArrayList实例。这样就不会对输入进行排重。这个聚合过程的结果就是产生一个包含所有值的数组。

我们需要记住的很重要的一点就是，用户的聚合计算应该是允许数据任意划分为多个部分进行计算而不会影响结果的。可以想象下写一个分而治之的算法，其中划分的数据完全不由用户控制而是由Hive进行控制的。比较正式的说明是，输入的行应该可以分成2个或多个子集，并可以分别对每个子集进行计算，同时允许将并行执行的各个子集的结果合并到其他并行执行的结果中，最终得到整个集合的结果。

下面的代码在Github中是可以查看到的。聚合过程的所有输入必须是基本数据类型。不像GenericUDF返回的是ObjectInspector对象，聚合过程返回的是GenericUDAFEvaluator的子类对象：

```

@Description(name = "collect", value = "_FUNC_(x) - Returns a list of objects. "+
"CAUTION will easily OOM on large data sets" )
public class GenericUDAFCollect extends AbstractGenericUDAFResolver {
    static final Log LOG = LogFactory.getLog(GenericUDAFCollect.class. getName());

    public GenericUDAFCollect() {
    }

    @Override
    public GenericUDAFEvaluator getEvaluator(TypeInfo[] parameters)
        throws SemanticException {

```

```

if (parameters.length != 1) {
    throw new UDFArgumentException(parameters.length - 1,
        "Exactly one argument is expected.");
}
if (parameters[0].getCategory() != ObjectInspector.Category. PRIMITIVE) {
    throw new UDFArgumentException(0,
        "Only primitive type arguments are accepted but "
        + parameters[0].getTypeName() + " was passed as parameter 1.");
}
return new GenericUDAFMkListEvaluator();
}
}

```

表13-1对基类中提供的部分方法进行了描述。

表13-1 基类中提供的方法描述

方法名	描述
init	Hive会调用此方法来初始实例化一个UDAF evaluator类
getNewAggregationBuffer	返回一个用于存储中间聚合结果的对象
iterate	将一行新的数据载入到聚合buffer中
terminatePartial	以一种可持久化的方法返回当前聚合的内容。这里所说的可持久化是指返回值只可以使用Java基本数据类型和array, 以及基本封装类型(例如Double), Hadoop中Writable类、list和map类型。不能使用用户自定义的类(即使实现了java.io.Serializable)
merge	将terminatePartial返回的中间部分聚合结果合并到当前聚合中
terminate	返回最终聚合结果给Hive

在init方法中, 在判断评估器所处的模式之后, 可以设置返回结果类型的对象检查器。

`iterate()`方法和`terminatePartial()`方法会在`map`端使用到；而`terminate()`方法和`merge()`方法会在`reduce`端使用到，用于生成最终结果。在所有情况下，合并过程都会产生大的列表：

```
public static class GenericUDAFMkListEvaluator extends GenericUDAEvaluator {  
    private PrimitiveObjectInspector inputOI;  
    private StandardListObjectInspector loi;  
    private StandardListObjectInspector internalMergeOI;  
  
    @Override  
    public ObjectInspector init(Mode m, ObjectInspector[] parameters)  
        throws HiveException {  
        super.init(m, parameters);  
        if (m == Mode.PARTIAL1) {  
            inputOI = (PrimitiveObjectInspector) parameters[0];  
            return ObjectInspectorFactory  
                .getStandardListObjectInspector(  
                    (PrimitiveObjectInspector) ObjectInspectorUtils  
                        .getStandardObjectInspector(inputOI));  
        } else {  
            if (!(parameters[0] instanceof StandardListObjectInspector)) {  
                inputOI = (PrimitiveObjectInspector) ObjectInspectorUtils  
                    .getStandardObjectInspector(parameters[0]);  
                return (StandardListObjectInspector) ObjectInspectorFactory  
                    .getStandardListObjectInspector(inputOI);  
            } else {  
                internalMergeOI = (StandardListObjectInspector) parameters[0];  
                inputOI = (PrimitiveObjectInspector)  
                    internalMergeOI.getListElementObjectInspector();  
                loi = (StandardListObjectInspector) ObjectInspectorUtils  
                    .getStandardObjectInspector(internalMergeOI);  
                return loi;  
            }  
        }  
    }  
}
```

余下的方法和类定义会定义`MkArrayAggregationBuffer`以及修改这个`buffer`的顶级方法。



提示

用户可能已经注意到Hive尝试尽可能地避免通过`new`创建对象。Hadoop和Hive依据这个规则创建尽可能少的临时对象，这样可以尽量减轻JVM的垃圾回收过程。在写UDF的时候，需要牢记这个原则，因为通常是可以引用重用对象的，而使用不变类型对象可能会导致出现bug！

```

...
static class MkArrayAggregationBuffer implements AggregationBuffer {
    List<Object> container;
}

@Override
public void reset(AggregationBuffer agg) throws HiveException {
    ((MkArrayAggregationBuffer) agg).container =
        new ArrayList<Object>();
}

@Override
public AggregationBuffer getNewAggregationBuffer()
    throws HiveException {
    MkArrayAggregationBuffer ret = new MkArrayAggregationBuffer();
    reset(ret);
    return ret;
}

// Mapside
@Override
public void iterate(AggregationBuffer agg, Object[] parameters)
    throws HiveException {
    assert (parameters.length == 1);
    Object p = parameters[0];

    if (p != null) {
        MkArrayAggregationBuffer myagg = (MkArrayAggregationBuffer) agg;
        putToList(p, myagg);
    }
}

// Mapside
@Override
public Object terminatePartial(AggregationBuffer agg)
    throws HiveException {
    MkArrayAggregationBuffer myagg = (MkArrayAggregationBuffer) agg;
    ArrayList<Object> ret = new ArrayList<Object>(myagg.container.size());
    ret.addAll(myagg.container);
    return ret;
}

@Override
public void merge(AggregationBuffer agg, Object partial)
    throws HiveException {
    MkArrayAggregationBuffer myagg = (MkArrayAggregationBuffer) agg;
    ArrayList<Object> partialResult =
        (ArrayList<Object>) internalMergeOI.getList(partial);
    for(Object i : partialResult) {
        putToList(i, myagg);
    }
}

@Override
public Object terminate(AggregationBuffer agg) throws HiveException {
    MkArrayAggregationBuffer myagg = (MkArrayAggregationBuffer) agg;
    ArrayList<Object> ret = new ArrayList<Object>(myagg.container.size());
    ret.addAll(myagg.container);
    return ret;
}

```

```

}

private void putToList(Object p, MkArrayAggregationBuffer myagg) {
    Object pCopy =
        ObjectInspectorUtils.copyToStandardObject(p, this.inputOI);
    myagg.container.add(pCopy);
}
}

```

使用collect函数可以返回所有聚合后的值的数组列表:

```

hive> dfs -cat ${HOME}/afile.txt;
twelve 12
twelve 1
eleven 11
eleven 10

hive> CREATE TABLE collecttest (str STRING, countVal INT)
> ROW FORMAT DELIMITED FIELDS TERMINATED BY '09' LINES TERMINATED BY '10';

hive> LOAD DATA LOCAL INPATH '${env:HOME}/afile.txt' INTO TABLE collecttest;

hive> SELECT collect(str) FROM collecttest;
[twelve,twelve,eleven,eleven]

```

函数concat_ws()的第1个参数是个分隔符, 其他的参数可以是字符串或者字符串数组。返回值是按照指定分隔符将所有字符串拼接在一起后的字符串。例如, 下面这个例子中我们使用逗号将一组字符串拼接成一个字符串:

```

hive> SELECT concat_ws( ',' , collect(str)) FROM collecttest;
twelve,twelve,eleven,eleven

```

GROUP_CONCAT函数可以按照如下语句通过组合使用GROUP BY、COLLECT和concat_ws()达到同样的效果:

```

hive> SELECT str, concat_ws( ',' , collect(cast(countVal AS STRING)))
> FROM collecttest GROUP BY str;
eleven 11,10
twelve 12,1

```

13.10 用户自定义表生成函数

尽管UDF可用来返回array(数组)和structure(结构体), 但是它们无法返回多列或多行。用户自定义表生成函数 (或简称UDTF) 通过提供一个可以返回多列甚至多行的程序接口来满足这个需求的。

13.10.1 可以产生多行数据的UDTF

我们已经在好几个例子中使用了explode方法。explode方法的输入是一个数组，而将数组中每个元素都作为一行进行输出。达到相同效果的另一种可选方式就是使用UDTF，基于某个输入产生多行输出。这里我们将展示一个UDTF，其效果类似于for循环。这个函数接受的是用户输入的起始数值和终止数值，然后输出N行数据：

```
hive> SELECT forx(1,5) AS i FROM collecttest;
1
2
3
4
5
```

这个类继承的是GenericUDTF接口。开始我们就声明了3个整型变量，也就是变量start、变量end和变量inc(代表递增量)。数组对象forwardObj用于存放要返回的结果行：

```
package com.jointhegrid.udf.collect;

import java.util.ArrayList;
import org.apache.hadoop.hive.ql.exec.UDFArgumentException;
import org.apache.hadoop.hive.ql.metadata.HiveException;
import org.apache.hadoop.hive.ql.udf.generic.GenericUDFUtils.*;
import org.apache.hadoop.hive.ql.udf.generic.GenericUDTF;
import org.apache.hadoop.hive.serde2.objectinspector.*;
import org.apache.hadoop.hive.serde2.objectinspector.primitive.*;
import org.apache.hadoop.io.IntWritable;

public class GenericUDTFFor extends GenericUDTF {

    IntWritable start;
    IntWritable end;
    IntWritable inc;

    Object[] forwardObj = null;
    ...
```

因为本函数的输入参数都是常数，所以在初始化的initialize方法中就可以确定各个变量的值了。对于本函数，非常量数据是无法到达evaluate方法进行处理的。第3个参数，也就是递增量是可选的，默认值是1：

```
...
@Override
public StructObjectInspector initialize(StructObjectInspector[] args)
    throws UDFArgumentException {
```

```
start=((WritableConstantIntObjectInspector) args[0])
    .getWritableConstantValue();
end=((WritableConstantIntObjectInspector) args[1])
    .getWritableConstantValue();
if (args.length == 3) {
    inc =((WritableConstantIntObjectInspector) args[2])
    .getWritableConstantValue();
} else {
    inc = new IntWritable(1);
}
...
```

本函数只会返回一行数据，而且这行数据的数据类型确定是整型的。我们需要提供一个列名，不过用户通常可以在后面重新命名列名：

```
...
this.forwardObj = new Object[1];
ArrayList<String> fieldNames = new ArrayList<String>();
ArrayList<ObjectInspector> fieldOIs = new ArrayList<ObjectInspector>();

fieldNames.add("col0");
fieldOIs.add(
    PrimitiveObjectInspectorFactory.getPrimitiveJavaObjectInspector(
        PrimitiveCategory.INT));

return ObjectInspectorFactory.getStandardStructObjectInspector(
    fieldNames, fieldOIs);
}
...
```

`process`方法是实际进行处理的过程。需要注意的是，这个方法的返回类型是`void`。这是因为UDTF可以向前获取零行或多行数据，而不像UDF，其只有唯一返回值。这种情况下会在`for`循环中对`forward`方法进行多次调用，这样每迭代一次就可以获取一行数据：

```
...
@Override
public void process(Object[] args)
    throws HiveException, UDFArgumentException {
for (int i = start.get(); i < end.get(); i = i + inc.get()) {
    this.forwardObj[0] = new Integer(i);
    forward(forwardObj);
}
}

@Override
public void close() throws HiveException {
}
}
```

13.10.2 可以产生具有多个字段的单行数据的UDTF

返回一行但是包含多列数据的UDTF的一个例子就是 `parse_url_tuple` 这个函数。这是个内置Hive函数，其有一个输入参数是一个URL链接，它还可以指定其他多个常数，来获取用户期望返回的特定部分：

```
hive> SELECT parse_url_tuple(weblogs.url, 'HOST', 'PATH')
    > AS (host, path) FROM weblogs;
google.com      /index.html
hotmail.com    /a/links.html
```

这种类型的UDTF的好处是URL只需要被解析一次，然后就可以返回多个列。这显然是个性能优势。而替代方式是：如果使用UDF的话，那么就需要写多个UDF，分别抽取出其URL的特定部分。使用UDF需要写更多的代码，同时因为URL需要多次进行解析，所以需要消耗更长的时间。可能需要类似于如下的使用方式：

```
SELECT PARSE_HOST(a.url) as host, PARSE_PORT(url) FROM weblogs;
```

13.10.3 可以模拟复杂数据类型的UDTF

UDTF可作为一种向Hive中增加更多复杂数据类型的技术。例如，某个复杂数据类型可以序列化成一个编码字符串，而UDTF可以在需要的时候对这个复杂数据类型进行反序列化。假设我们有一个名为Book的Java类。Hive无法直接处理这样的数据类型，不过Book对象可以编码成字符串格式，并从字符串格式解码出来：

```
public class Book {
  public Book () { }
  public String isbn;
  public String title;
  public String [] authors;

  /* note: this system will not work if your table is
     using '|' or ',' as the field delimiter! */
  public void fromString(String parts){
    String [] part = part.split("\|");
    isbn = Integer.parseInt( part[0] );
    title = part[1] ;
    authors = part[2].split(",");
  }

  public String toString(){
```

```
    return isbn+"\t"+title+"\t"+StringUtils.join(authors, ",");  
}  
}
```

假设Book对象的字符串格式是如下这种形式的，同时假设目前为止还无法使用SerDe划分来按照分隔符“|”和“，”进行分割：

```
hive> SELECT * FROM books;  
5555555|Programming Hive|Edward,Dean,Jason
```

对于原始数据格式，可能是按照如下方式进行分割得到的：

```
hive> SELECT cast(split(book_info, "\|")[0] AS INTEGER) AS isbn FROM books  
> WHERE split(book_info, "\|")[1] = "Programming Hive";  
5555555
```

这个HiveQL语句可以正确地执行，不过对于最终用户来说有更加简单的处理方式。例如，写这种类型的查询可能需要参考相应的文档来确定使用哪个字段以及使用哪种数据类型，还要牢记类型转换的规则，以及其他一些事项。相比之下，使用UDTF可以使HiveQL更加简洁和方便阅读。下面这个例子，使用到了parse_book()这个UDTF：

```
hive> FROM (  
  > parse_book(book_info) AS (isbn, title, authors) FROM Book ) a  
  > SELECT a.isbn  
  > WHERE a.title="Programming Hive"  
  > AND array_contains (authors, 'Edward');  
5555555
```

函数parse_book()允许Hive返回不同数据类型的多个列，分别用来表示book的各个字段：

```
package com.jointhegrid.udf.collect;  
  
import java.util.ArrayList;  
import org.apache.hadoop.hive.ql.exec.UDFArgumentException;  
import org.apache.hadoop.hive.ql.metadata.HiveException;  
import org.apache.hadoop.hive.ql.udf.generic.GenericUDTF;  
import org.apache.hadoop.hive.serde2.objectinspector.ObjectInspector;  
import org.apache.hadoop.hive.serde2.objectinspector.ObjectInspectorFactory;  
import org.apache.hadoop.hive.serde2.objectinspector.PrimitiveObjectInspector  
.PrimitiveCategory;  
import org.apache.hadoop.hive.serde2.objectinspector.StructObjectInspector;  
import org.apache.hadoop.hive.serde2.objectinspector.primitive  
.PrimitiveObjectInspectorFactory;  
import org.apache.hadoop.hive.serde2.objectinspector.primitive  
.WritableConstantStringObjectInspector;  
import org.apache.hadoop.hive.serde2.objectinspector.primitive
```

```

    .WritableStringObjectInspector;
import org.apache.hadoop.io.Text;

public class UDTFBook extends GenericUDTF{

    private Text sent;
    Object[] forwardObj = null;
    ...
}

```

这个函数将会返回包含有3个属性信息的数组，其中，ISBN是个整数，title（书名）是个字符串，authors（作者）也是字符串。需要注意的是，所有的UDF都是可以返回嵌套数据类型的，例如，我们可以返回包含字符串数组的数组：

```

...
@Override
public StructObjectInspector initialize(ObjectInspector[] args)
    throws UDFArgumentException {

    ArrayList<String> fieldNames = new ArrayList<String>();
    ArrayList<ObjectInspector> fieldOIs = new ArrayList<ObjectInspector>();

    fieldNames.add("isbn");
    fieldOIs.add(PrimitiveObjectInspectorFactory.getPrimitiveJavaObjectInspector(
        PrimitiveCategory.INT));

    fieldNames.add("title");
    fieldOIs.add(PrimitiveObjectInspectorFactory.getPrimitiveJavaObjectInspector(
        PrimitiveCategory.STRING));

    fieldNames.add("authors");
    fieldOIs.add( ObjectInspectorFactory.getStandardListObjectInspector(
        PrimitiveObjectInspectorFactory.getPrimitiveJavaObjectInspector(
            PrimitiveCategory.STRING)
    )
);

    forwardObj= new Object[3];
    return ObjectInspectorFactory.getStandardStructObjectInspector(
        fieldNames, fieldOIs);
}
...

```

process方法只会返回一行。不过，对象数组中的每个元素都将绑定一个特定的变量：

```

...
@Override
public void process(Object[] os) throws HiveException {
    sent = new Text(((StringObjectInspector)args[0])
        .getPrimitiveJavaObject(os[0]));
    String parts = new String(this.sent.getBytes());
}

```

```

        String [] part = parts.split("\\|");
        forwardObj[0]=Integer.parseInt( part[0] );
        forwardObj[1]=part[1] ;
        forwardObj[2]=part[2].split(",");
        this.forward(forwardObj);
    }

@Override
public void close() throws HiveException {
}
}

```

我们在Book这个UDTF后面使用了AS，这样可以允许用户自定义结果字段的别名。这些别名可以在查询的其他部分使用到，而无需重复从Book中解析出信息：

```

client.execute(
    "create temporary function book as 'com.jointhegrid.udf.collect.UDTFBook'");
client.execute("create table booktest (str string)");
client.execute(
    "load data local inpath '" + p.toString() + "' into table booktest");
client.execute("select book(str) AS (book, title, authors) from booktest");
[555 Programming Hive "Dean", "Jason", "Edward"]

```

13.11 在 UDF中访问分布式缓存

UDF是可以访问分布式缓存、本地文件系统、甚至分布式文件系统中的文件的。不过这样的访问应该小心使用，因为这种使用会显著地降低执行效率。

Hive的一个常用的使用场景就是分析网页日志。比较大众的一个操作就是基于IP地址进行地理位置定位。Maxmind提供了一个GeoIP数据库，并提供了Java API来访问这个数据库。通过将这个API包装成一个UDF，就可以在Hive查询中通过IP地址查询对应的地理位置信息。

GeoIP API会使用一个较小的数据文件。其对于通过UDF访问一个分布式缓存文件来说是非常理想的。本例的完整代码可以通过如下链接获得：<https://github.com/edwardcapriolo/hive-geoip/>。

ADD FILE命令用于通过Hive将数据文件加载到分布式缓存中。而ADD JAR 命令可以将指定的Java JAR文件加载到分布式缓存和类路径中。最后，在执行查询前需要创建临时函数：

```

hive> ADD FILE GeoIP.dat;
hive> ADD JAR geo-ip-java.jar;
hive> ADD JAR hive-udf-geo-ip-jtg.jar;
hive> CREATE TEMPORARY FUNCTION geoip
    > AS 'com.jointhegegrid.hive.udf.GenericUDFGeoIP';

hive> SELECT ip, geoip(source_ip, 'COUNTRY_NAME', './GeoIP.dat') FROM weblogs;
209.191.139.200      United States
10.10.0.1            Unknown

```

(译者注: 这个SQL中source_ip应该是ip, 正确的语句应该是SELECT ip, geoip(ip, 'COUNTRY_NAME', './GeoIP.dat') FROM weblogs。)

上面的例子中返回了2条记录, 其中一条显示这个IP是来自美国的, 而另一条显示对应的IP无对应的地理位置信息。

这个geoip()函数含有3个参数: 第1个参数是IP地址, 可以是字符串类型或者long类型; 第2个参数是一个字符串, 可选的值有COUNTRY_NAME或DMA_CODE; 最后1个参数是数据文件名, 这个文件已经是加载到分布式缓存中了。

对UDF的第一次调用 (也就是触发调用Java函数中evaluate方法) 会实例化一个LookupService对象来使用分布式缓存中的那个数据文件。这个查询是需要保存在一个引用中的。因此, 其只需在map或者reduce task的初始化阶段初始一次, 就可在对应task的整个生命周期中使用。需要注意的是, LookupService具有自己的内置缓存, 也就是LookupService.GEOIP_MEMORY_CACHE。因此, 这个优化可以避免在查询IP时, 频繁访问磁盘。

下面是evaluate()方法的源码:

```

@Override
public Object evaluate(DeferredObject[] arguments) throws HiveException {
    if (argumentOIs[0] instanceof LongObjectInspector) {
        this.ipLong = ((LongObjectInspector)argumentOIs[0]).get(arguments[0].get());
    } else {
        this.ipString = ((StringObjectInspector)argumentOIs[0])
            .getPrimitiveJavaObject(arguments[0].get());
    }
    this.property = ((StringObjectInspector)argumentOIs[1])
        .getPrimitiveJavaObject(arguments[1].get());
    if (this.property != null) {
        this.property = this.property.toUpperCase();
    }
    if (ls ==null){

```

```

if (argumentOIs.length == 3){
    this.database = ((StringObjectInspector)argumentOIs[1])
        .getPrimitiveJavaObject(arguments[2].get());
    File f = new File(database);
    if (!f.exists())
        throw new HiveException(database+" does not exist");
    try {
        ls = new LookupService ( f , LookupService.GEOIP_MEMORY_CACHE );
    } catch (IOException ex){
        throw new HiveException (ex);
    }
}
...

```

evaluate方法中的if语句决定了将返回哪个方法的数据。在本例中，需要返回的内容是国家名：

```

...
if (COUNTRY_PROPERTIES.contains(this.property)) {
    Country country = ipString != null ?
        ls.getCountry(ipString) : ls.getCountry(ipLong);
    if (country == null) {
        return null;
    } else if (this.property.equals(COUNTRY_NAME)) {
        return country.getName();
    } else if (this.property.equals(COUNTRY_CODE)) {
        return country.getCode();
    }
    assert(false);
} else if (LOCATION_PROPERTIES.contains(this.property)) {
    ...
}

```

13.12 以函数的方式使用注解

本章中我们提及过Description标注，并介绍了其用于在运行时为Hive方法提供说明文档。UDF中还存在有其他的标注，正确使用这些标注可以使得函数更加简单，甚至有时对于某些Hive查询，可以提高执行效率：

```

public @interface UDFType {
    boolean deterministic() default true;
    boolean stateful() default false;
    boolean distinctLike() default false;
}

```

13.12.1 定数性 (deterministic) 标注

默认情况下，对于大多数的查询来说，都是满足定数性的，因为它们本身就具有定数性。当然rand()函数是个例外。

如果一个UDF是非定数的，那么就不会包含在分区裁剪中。

下面是使用rand()函数的，具有非定数性的查询的一个例子：

```
SELECT * FROM t WHERE rand() < 0.01;
```

如果rand()是定数的，那么结果只会在计算阶段计算一次。因为包含有rand()的查询是非定数的，因此对于每行数据，rand()的值都需要重新计算一次。

13.12.2 状态性 (stateful) 标注

几乎所有的UDF默认都是有状态性的，而rand()函数是无状态性的，因为其每次调用都返回不同的值。stateful标注适用于如下情况。

① 有状态性的UDF只能使用在SELECT语句后面，而不能使用到其他如WHERE、ON、ORDER、GROUP等语句后面。

② 当一个查询语句中存在有状态性的UDF时，那么隐含的信息就是，SELECT将会和TRANSFORM（例如，一个DISTRIBUTE、CLUSTER、SORT语句）进行类似的处理，然后会在对应的reducer内部进行执行，以保证结果是预期的结果。

③ 如果状态性标记stateful设置值为true，那么这个UDF同样应该作为非定数性的（即使这时定数性标记deterministic的值是显式设置为true的）。

详细信息请参考如下链接：

<https://issues.apache.org/jira/browse/HIVE-1994>。

13.12.3 唯一性

有些函数，即使其输入的列的值是非排重值，其结果也是类似于使用了DISTINCT进行了排重操作，这类场景可定义为具有唯一性。这样的例子有min和max函数，即使实际数据中有重复值，其最终结果也是唯一排重值。

13.13 宏命令

宏命令提供了在HiveQL中调用其他函数和操作符来定义函数的功能。对于特定的情况，使用宏命令要比使用Java编写UDF或使用Hive的streaming功能更加方便，因为宏命令无需额外编写代码或脚本。

可以使用CREATE TEMPORARY MACRO语法来定义一个宏命令。下面是一个使用宏命令创建SIGMOID函数的例子：

```
hive> CREATE TEMPORARY MACRO SIGMOID (x DOUBLE) 1.0 / (1.0 + EXP(-x));
hive> SELECT SIGMOID(2) FROM src LIMIT 1;
```

(译者注：这个功能实际到Apache Hive 0.10.0版本还没有真正提供，对于这个问题请参考：<https://issues.apache.org/jira/browse/HIVE-2655>)

第14章 Streaming

Hive是通过利用或扩展Hadoop的组件功能来运行的，常见的抽象有InputFormat、OutputFormat、Mapper和Reducer，还包含一些自己的抽象接口，例如SerializerDeserializer (SerDe)、用户自定义函数(UDF) 和StorageHandlers。

这些组件都是Java组件，不过Hive将这些复杂的底层实现隐藏起来了，而提供给用户通过SQL语句执行的方式，而不是使用Java代码。

Streaming提供了另一种处理数据的方式。在streaming job中，Hadoop Streaming API会为外部进程开启一个I/O管道。然后数据会被传给这个进程，其会从标准输入中读取数据，然后通过标准输出来写结果数据，最后返回到Streaming API job。尽管Hive并没有直接使用Hadoop的Streaming API，不过它们的工作方式是一样的。

这种管道计算模型对于Unix操作系统以及其衍生系统，如Linux和Mac OS X的用户来说是非常熟悉的。



提示

Streaming的执行效率通常会比对应的编写UDF或改写InputFormat对象的方式要低。管道中序列化然后反序列化数据通常是低效的，而且以通常的方式很难调试整个程序。不过，对于快速原型设计和支持非Java编写的已有代码来说是非常有用的。对于那些不想写Java代码的Hive用户来说，这也是个高效的方式。

Hive中提供了多个语法来使用streaming，包括：MAP()、REDUCE()和TRANSFORM()。要注意的重要的一点是MAP()实际上并非可以强制在map阶段执行streaming，正如reduce并非可以强制在reduce阶段执行streaming一样。因为这个原因，对于相同的功能，通

常建议使用常规的TRANSFORM()语句，这样可以避免误导读者对查询语句产生疑惑。

对于我们的streaming例子，我们将使用到一个表名为a的小表，其中有2个字段，分别是col1 和 col2，它们都是INT类型的，表中有2行数据：

```
hive> CREATE TABLE a (col1 INT, col2 INT)
> ROW FORMAT DELIMITED FIELDS TERMINATED BY '\t';

hive> SELECT * FROM a;
4      5
3      2

hive> DESCRIBE a;
a      int
b      int
```

14.1 恒等变换

最基本的streaming job就是恒等运算。/bin/cat这个shell命令可以将传递给它的数据直接输出，所以满足恒等运算。本例中，/bin/cat这个shell假定已经安装到所有的TaskTracker节点了。实际上任意的Linux系统都会包含有这个脚本的！稍后，我们将展示当一些程序没有安装到集群中时，通过Hive如何将这些程序“加载”到集群中：

```
hive> SELECT TRANSFORM (a, b)
>   USING '/bin/cat' AS newA, newB
>   FROM default.a;
4      5
3      2
```

14.2 改变类型

TRANSFORM返回的字段的数据类型默认是字符串类型的。不过可以通过如下语法将类型转换成其他数据类型：

```
hive> SELECT TRANSFORM (col1, col2)
>   USING '/bin/cat' AS (newA INT , newB DOUBLE) FROM a;
4      5.0
3      2.0
```

14.3 投影变换

Streaming中可以使用cut命令提取或者映射出特定的字段。换句话说，可以达到和SELECT语句相同的行为：

```
hive> SELECT TRANSFORM (a, b)
  > USING '/bin/cut -f1'
  > AS newA, newB FROM a;
4      NULL
3      NULL
```

可以注意到，上面的例子中，查询从外部处理过程中返回的只有一个字段，而实际期望的是2个字段，因此字段newB的值总是NULL。默认情况下，TRANSFORM需要2个字段，不过实际上可以为比其小的任意个数的字段：

```
hive> SELECT TRANSFORM (a, b)
  > USING '/bin/cut -f1'
  > AS newA FROM a;
4
3
```

14.4 操作转换

/bin/sed程序（对于Mac OS X系统是/usr/bin/sed）是一个流编辑器。其可以接受输入数据流，然后按照用户的指定进行编辑，最后将编辑后的结果输出的输出数据流中。如下例子中将字符串“4”替換成了字符串“10”：

```
hive> SELECT TRANSFORM (a, b)
  > USING '/bin/sed s/4/10/'
  > AS newA, newB FROM a;
10 5
3      2
```

14.5 使用分布式内存

到目前为止所列举的streaming例子都是UNIX系统或其衍生系统自带的如cat和sed这样的系统脚本程序。当一个查询所需要的文件没有在每个TaskTracker上事先安装好时，用户需要使用分布式缓存将数据或

者程序文件传输到集群中，然后在job完成后会清理掉这些数据和文件。（译者注：Hadoop 的分布式缓存可以对缓存内的文件安装LRU原则进行删除，因此并非是job一结束就立即删除掉文件的。）

这个功能很有用，因为在大规模集群上安装（有时需要卸载）大量的小组件会成为一件很有负担的事情。同时，缓存中会独立保存每个job的缓存文件，而不会相互干扰。

下面的例子是一个将摄氏温度转换成华氏温度的bash shell脚本：

```
while read LINE
do
  res=$(echo "scale=2;((9/5) * $LINE) + 32" | bc)
  echo $res
done
```

可以在本地执行这个脚本来测试一下。这个脚本不会提示输入。输入100，然后按回车键，这时这个进程会通过标准输出打印出212.00；输入另一个数值，然后程序就会返回另一个相应的结果。用户可以持续地输入数值，也可以通过Control + D组合键退出程序终止输入。

```
#!/bin/bash
$ sh ctof.sh
100
212.00
0
32.00
^D
```

Hive的ADD FILE功能可以将文件加入到分布式缓存中。而被增加的文件会被存储到每个task节点机器的当前工作目录下。这样可以使得transform task直接使用脚本而不用确定到哪里去找这些文件：

```
hive> ADD FILE ${env:HOME}/prog_hive/ctof.sh;
Added resource: /home/edward/prog_hive/ctof.sh

hive> SELECT TRANSFORM(col1) USING 'ctof.sh' AS convert FROM a;
39.20
37.40
```

14.6 由一行产生多行

到目前为止所列举的例子都是获取一行输入然后产生一行输出。同样，可以使用Streaming对每个输入行产生多行输出。这个功能可以产生类似于EXPLODE() UDF和LATERAL VIEW语法^[1]的输出。

给定一个输入文件 \$HOME/kv_data.txt，其内容如下：

```
k1=v1, k2=v2
k4=v4, k5=v5, k6=v6
k7=v7, k7=v7, k3=v7
```

我们希望这些数据能够以表格的形式展示。这样就可以让常见的HiveQL操作符处理这些行：

```
k1    v1
k2    v2
k4    k4
```

创建如下这个Perl脚本，然后保存为\$HOME/split_kv.pl：

```
#!/usr/bin/perl
while (<STDIN>) {
    my $line = $_;
    chomp($line);
    my @kvs = split(/,/, $line);
    foreach my $p (@kvs) {
        my @kv = split(/=/, $p);
        print $kv[0] . "\t" . $kv[1] . "\n";
    }
}
```

创建一个名为kv_data的表。这张表只定义了一个字段。行格式无需进行配置，因为streaming脚本会对输入字段进行分割：

```
hive> CREATE TABLE kv_data ( line STRING );
hive> LOAD DATA LOCAL INPATH '${env:HOME}/kv_data.txt' INTO TABLE kv_data;
```

对源表使用transform脚本。这样之前凌乱的，一行多个条目的格式就转化成了一个具有2个字段的键-值对数据：

```
hive> SELECT TRANSFORM (line)
  > USING 'perl split_kv.pl'
  > AS (key, value) FROM kv_data;
k1    v1
k2    v2
k4    v4
```

```
k5      v5
k6      v6
k7      v7
k7      v7
k3      v7
```

14.7 使用streaming进行聚合计算

同样可以使用streaming做类似于Hive的内置函数SUM一样的聚合运算。这是因为streaming处理过程可以对每行输入返回0或多行输出。

为了能在一个外部应用程序中完成聚合，脚本中在循环外面先定义了一个计数器，然后，循环内部不断从输入流中读取输入并进行计算，最终输出sum求和结果：

```
#!/usr/bin/perl
my $sum=0;
while (<STDIN>) {
    my $line = $_;
    chomp($line);
    $sum+=$sum+$line;
}
print $sum;
```

创建一个表并导入整数数据，每行一个整数，用于测试：

```
hive> CREATE TABLE sum (number INT);
hive> LOAD DATA LOCAL INPATH '${env:HOME}/data_to_sum.txt' INTO TABLE sum;
hive> SELECT * FROM sum;
5
5
4
```

将streaming程序增加到分布式缓存中，并在TRANSFORM查询中使用。这个处理过程将会返回一行结果，也就是对输入求和后的结果：

```
hive> ADD FILE ${env:HOME}/aggregate.pl;
Added resource: /home/edward/aggregate.pl

hive> SELECT TRANSFORM (number)
      >   USING 'perl aggregate.pl' AS total FROM sum;
14
```

不过可惜的是，不能够像UDAF SUM()那样在单个查询中执行多个TRANSFORM过程。例如：

```
hive> SELECT sum(number) AS one, sum(number) AS two FROM sum;
14      14
```

同时，对于中间数据，如果不使用CLUSTER BY或者DISTRIBUTE BY的话，那么这个job可能会执行单个的非常长时间的map或者reduce task。尽管并非所有的操作都可以并行执行，不过大多数操作还是可以的。下一节将讨论如何在需要的时候以并行的方式执行streaming。

14.8 CLUSTER BY、DISTRIBUTE BY、 SORT BY

Hive提供了语法来控制数据是如何被分发和排序的。这些功能可以应用在大多数的查询中，不过在执行streaming处理时显得特别有用。例如，具有相同键的数据需要分发到同一个处理节点上，或者数据需要按照指定列或指定函数进行排序。Hive提供了多种方式来控制这种行为。

第1种控制这种行为的方法就是CLUSTER BY语句，其可以确保类似的数据可以分发到同一个reduce task中，而且保证数据是有序的。

为了演示CLUSTER BY的用法，让我们来看一个特殊的例子：通过另外一种方式来实现第1章中所介绍的Word Count算法。现在，我们将使用到TRANSFORM功能和2个Python脚本，一个脚本用于将读取的文本的每行内容分割成单词；另一个脚本用于接受字频数据流以及单词的中间计数值（大多数是数字“1”），然后对每个单词的词频求和汇总。

下面是第1个Python脚本，其可以按照空格将每行内容分割成单词（按空格划分对于标点符号等可能不太合适）：

```
import sys
for line in sys.stdin:
    words = line.strip().split()
```

```
for word in words:  
    print "%s\t1" % (word.lower())
```

不必说明所有的Python语法，可以很容易看到，这个脚本从通用模块sys中引入了常见的函数，然后循环获取“标准输入流”中每行内容（也就是调用stdin函数），再按照空格对每行内容进行划分，生成一个单词集合words，然后遍历整个集合并输出每个单词以及一个制表符（也就是\t），最后输出每个单词对应的词频^[2]。

在我们展示第2个Python脚本之前，让我们先讨论下传递给这个脚本的数据。在我们的TRANSFORM Hive查询中，我们将对第1个Python脚本的输出词组使用CLUSTER BY。这样可以将所有相同的单词分配到同一组中，每行一对数据，每对的数据形式是单词\t次数：

```
word1 1  
word1 1  
word1 1  
word2 1  
word3 1  
word3 1  
...
```

因此，第2个Python脚本将会更复杂些，因为其需要缓存当前处理的单词，以及迄今为止这个单词出现的次数。当处理下一个单词时，这个脚本需要输出上一个单词的词频数，然后重置缓存。

下面就是第2个Python脚本：

```
import sys  
  
(last_key, last_count) = (None, 0)  
for line in sys.stdin:  
    (key, count) = line.strip().split("\t")  
    if last_key and last_key != key:  
        print "%s\t%d" % (last_key, last_count)  
        (last_key, last_count) = (key, int(count))  
    else:  
        last_key = key  
        last_count += int(count)  
  
if last_key:  
    print "%s\t%d" % (last_key, last_count)
```

我们将假设这2个Python脚本都在用户根目录下。

最后，我们来看下2个脚本结合使用的Hive查询语句。首先，我们通过CREATE TABLE语句创建一个输入表，表内容包含多行的文本数据。这个表我们在第1章使用过。任意文本文件都可以作为这张表的数据。其次，创建的表word_count用于保存计算后的输出结果。其有2个字段，一个是word(表示单词)，一个是count(表示次数)。同时字段分隔符是\t。最后就是结合使用这2个脚本进行处理的TRANSFORM语句了：

```
hive> CREATE TABLE docs (line STRING);

hive> CREATE TABLE word_count (word STRING, count INT)
> ROW FORMAT DELIMITED FIELDS TERMINATED BY '\t';

hive> FROM (
>   FROM docs
>   SELECT TRANSFORM (line) USING '${env:HOME}/mapper.py'
>   AS word, count
>   CLUSTER BY word) wc
>   INSERT OVERWRITE TABLE word_count
>   SELECT TRANSFORM (wc.word, wc.count) USING '${env:HOME}/reducer.py'
>   AS word, count;
```

USING语句指定了Python脚本所在的绝对路径。

替代CLUSTER BY的最方便的方式就是使用DISTRIBUTE BY和SORT BY。使用它们的常见场景就是，用户期望将数据按照某个字段划分，然后按照另一个字段排序。实际上，CLUSTER BY word 等价于DISTRIBUTE BY word SORT BY word ASC。

如下TRANSFORM查询的字频输出结果是按照降序排序的：

```
FROM (
  FROM docs
  SELECT TRANSFORM (line) USING '/.../mapper.py'
  AS word, count
  DISTRIBUTE BY word SORT BY word DESC) wc
  INSERT OVERWRITE TABLE word_count
  SELECT TRANSFORM (wc.word, wc.count) USING '/.../reducer.py'
  AS word, count;
```

使用CLUSTER BY或者使用结合SORT BY的DISTRIBUTE BY是非常重要的。因为如果没有这些指示，Hive可能无法合理地并行执行job，所有的数据可能都会分发到同一个reducer上，这样就会导致整体job执行时间延长。

14.9 GenericMR Tools for Streaming to Java

通常情况下，使用streaming是为了将非Java的代码结合到Hive中。正如我们所看见的，streaming几乎适用于所有的语言。使用Java编写streaming也是可以的，而且Hive中包含了GenericMR API来试图为streaming提供类似于Hadoop的MapReduce API的这样的接口：

```
FROM (
  FROM src
  MAP value, key
  USING 'java -cp hive-contrib-0.9.0.jar
    org.apache.hadoop.hive.contrib.mr.example.IdentityMapper'
  AS k, v
  CLUSTER BY k) map_output
REDUCE k, v
USING 'java -cp hive-contrib-0.9.0.jar
  org.apache.hadoop.hive.contrib.mr.example.WordCountReduce'
AS k, v;
```

为了清楚IdentityMapper是怎么编写的，我们可以看一下GenericMR所提供的接口。其中Mapper接口用于实现常见的Mapper实现方法。其提供了一个map方法，这里输入是字符串数组类型String[]的列值：

```
package org.apache.hadoop.hive.contrib.mr;

public interface Mapper {
    void map(String[] record, Output output) throws Exception;
}
```

IdentityMapper不会对输入数据做任何改变而会将其传递给收集器(collector)。在功能上这和本章前面部分所介绍的/bin/cat的功能是一致的：

```
package org.apache.hadoop.hive.contrib.mr.example;

import org.apache.hadoop.hive.contrib.mr.GenericMR;
import org.apache.hadoop.hive.contrib.mr.Mapper;
import org.apache.hadoop.hive.contrib.mr.Output;

public final class IdentityMapper {
    public static void main(final String[] args) throws Exception {
        new GenericMR().map(System.in, System.out, new Mapper() {
            @Override
            public void map(final String[] record, final Output output) throws Exception {
                output.collect(record);
            }
        });
    }
}
```

```
}

private IdentityMapper() {
}

}
```

Reducer接口提供了第一列字符串，而其他列可以通过记录迭代器获得。每次迭代都会返回一对字符串，其中第0个元素是重复的键而其下一次元素是值。output对象表示输出结果：

```
package org.apache.hadoop.hive.contrib.mr;

import java.util.Iterator;

public interface Reducer {
    void reduce(String key, Iterator<String[]> records, Output output)
        throws Exception;
}
```

WordCountReduce类中有一个累加器用于对记录迭代器中的每个元素进行计数。当所有的记录都被计数后，就会生成一个由键及其对应次数所组成的数组作为结果：

```
package org.apache.hadoop.hive.contrib.mr.example;

import java.util.Iterator;
import org.apache.hadoop.hive.contrib.mr.GenericMR;
import org.apache.hadoop.hive.contrib.mr.Output;
import org.apache.hadoop.hive.contrib.mr.Reducer;

public final class WordCountReduce {

    private WordCountReduce() {
    }

    public static void main(final String[] args) throws Exception {
        new GenericMR().reduce(System.in, System.out, new Reducer() {
            public void reduce(String key, Iterator<String[]> records, Output output)
                throws Exception {
                int count = 0;
                while (records.hasNext()) {
                    // note we use col[1] -- the key is provided again as col[0]
                    count += Integer.parseInt(records.next()[1]);
                }
                output.collect(new String[] {key, String.valueOf(count)});
            }
        });
    }
}
```

14.10 计算cogroup

在MapReduce程序中经常会对多数据集进行JOIN连接处理，然后使用TRANSFORM进行处理。使用UNION ALL和CLUSTER BY，我们可以实现GROUP BY操作的常见效果。（译者注：这里应该是COGROUP BY 而不是 GROUP BY）



提示

Pig提供了一个原生的COGROUP BY 操作。

假设我们有多个不同源的日志文件，它们具有相同的schema。我们期望将它们合并在一起，然后通过一个reduce_script脚本进行分析：

```
FROM (
  FROM (
    FROM order_log ol
    -- User Id, order Id, and timestamp:
    SELECT ol.userid AS uid, ol.orderid AS id, av.ts AS ts

    UNION ALL

    FROM clicks_log cl
    SELECT cl.userid AS uid, cl.id AS id, ac.ts AS ts
  ) union_msgs
SELECT union_msgs.uid, union_msgs.id, union_msgs.ts
CLUSTER BY union_msgs.uid, union_msgs.ts) map
INSERT OVERWRITE TABLE log_analysis
SELECT TRANSFORM(map.uid, map.id, map.ts) USING 'reduce_script'
AS (uid, id, ...);
```

[1]这个例子所使用到的源码和概念来自于Larry Ogorodnek在2009年7月14日在Bizo开发博客上发表的“Custom Map Scripts and Hive”博文。

[2]这是最简单的处理方式。我们也可以缓存单词的次数并直接输出最终词频数。这样处理会减少I/O开销，因此将会更快，但是也因此，其实现起来要更加复杂。

第15章 自定义Hive文件和记录格式

Hive可以通过多种方式自定义其功能。首先，Hive具有变量和属性，这个我们在第2.7.2节“变量和属性”中讨论过了。其次，用户可以通过自定义UDF来扩展Hive功能，在第13章我们有讨论过。最后，用户可以自定义文件和记录格式，这个是本章将进行讨论的内容。

15.1 文件和记录格式

Hive中文件格式间具有明显的差异，例如文件中记录的编码方式、记录格式以及记录中字节流的编码方式都是不同的。

本书到目前为止都是使用文本文件格式存储的，也就是CREATE TABLE语句中默认的STORED AS TEXTFILE（请参考第3.3节“文本文件数据编码”中的介绍）。在文本文件中每一行数据就是一条记录。大多数情况下这些记录使用默认的分隔符，偶然有一些样例数据使用逗号或回车键作为字段分隔符。不过，文本文件统一可以包含JSON或者XML“文档”。

对于Hive而言，文本文件格式选择和记录格式是对应的。我们将首先讨论文本格式，然后再讨论不同的记录格式，以及在Hive中如果使用这些格式。

15.2 阐明CREATE TABLE句式

贯穿本书，我们已经介绍了创建表的例子。用户可能已经发现CREATE TABLE语句具有多种多样的语法。例如STORED AS SEQUENCEFILE、ROW FORMAT DELIMITED、SERDE、INPUTFORMAT、OUTPUTFORMAT这些语法。本章将涵括这个语法的大部分内容并给出样例。但是需要注意的是，某些语法是其他语法的快捷用法，也就是说，可以使概念变得更易理解的语法。例如，语法STORED AS SEQUENCEFILE的替代方式是指定INPUTFORMAT为

org.apache.hadoop.mapred.SequenceFileInputFormat，并指定
OUTPUTFORMAT为
org.apache.hadoop.hive.ql.io.HiveSequenceFileOutputFormat。

下面我们创建一些表然后使用DESCRIBE TABLE EXTENDED语句来查看下内部的实际变化情况。首先，我们将创建一个简单的表，然后对其进行描述（这里我们对输出进行了格式化，实际上Hive本身输出效果不是这样）[（译者注：从Apache Hive v0.10.0开始 EXTENDED 输出也将是部分格式化的，和当前的输出效果还是有差异的）](#)：

```
hive> create table text (x int);
hive> describe extended text;
OK
x    int

Detailed Table Information
Table(tableName:text, dbName:default, owner:edward, createTime:1337814583,
lastAccessTime:0, retention:0,
sd:StorageDescriptor(
  cols:[FieldSchema(name:x, type:int, comment:null)],
  location:/user/hive/warehouse/text,
  inputFormat:org.apache.hadoop.mapred.TextInputFormat,
  outputFormat:org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat,
  compressed:false,
  numBuckets:-1,
  serdeInfo:SerDeInfo(
    name:null,
    serializationLib:org.apache.hive.serde2.lazy.LazySimpleSerDe,
    parameters:{serialization.format=1}
  ),
  bucketCols:[], sortCols:[], parameters:{}),
  partitionKeys:[],
  parameters:{transient_lastDdlTime=1337814583},
  viewOriginalText:null, viewExpandedText:null, tableType:MANAGED_TABLE
)
```

现在我们再使用STORED AS SEQUENCEFILE语句创建一张表，用于对比：

```
hive> CREATE TABLE seq (x int) STORED AS SEQUENCEFILE;
hive> DESCRIBE EXTENDED seq;
OK
x    int

Detailed Table Information
Table(tableName:seq, dbName:default, owner:edward, createTime:1337814571,
lastAccessTime:0, retention:0,
sd:StorageDescriptor(
  cols:[FieldSchema(name:x, type:int, comment:null)],
  location:/user/hive/warehouse/seq,
```

```
inputFormat:org.apache.hadoop.mapred.SequenceFileInputFormat,
outputFormat:org.apache.hadoop.hive.ql.io.HiveSequenceFileOutputFormat,
compressed:false, numBuckets:-1,
serdeInfo:SerDeInfo(
  name:null,
  serializationLib:org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe,
  parameters:{serialization.format=1}
),
bucketCols:[], sortCols:[], parameters:{}), partitionKeys:[],
parameters:{transient_lastDdlTime=1337814571},
viewOriginalText:null, viewExpandedText:null, tableType:MANAGED_TABLE
)
Time taken: 0.107 seconds
```

除非被Hive的强大功能所迷惑，否则很容易找出这2个表的差异。STORED AS SEQUENCEFILE语句改变了InputFormat和OutputFormat的值：

```
inputFormat:org.apache.hadoop.mapred.TextInputFormat,
outputFormat:org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat,
inputFormat:org.apache.hadoop.mapred.SequenceFileInputFormat,
outputFormat:org.apache.hadoop.hive.ql.io.HiveSequenceFileOutputFormat,
```

当从表中读取数据时，Hive会使用到InputFormat；而当向表中写入数据时；其会使用OutputFormat。



提示

InputFormat会从文件中读取键-值对。默认情况下，Hive会直接忽略掉键的内容而只是有值中的数据。这是因为键来自于TextInputFormat，是表示块中的字节边界的一个长整型数值(其并非用户数据)。

本章后面部分将描述表元数据的其他方面信息。

15.3 文件格式

我们在第3.3节“文本文件数据编码”中讨论过使用的最简单的数据格式是文本文件格式，可以任意的分隔符进行分割。同时这也是默认

的文件格式，等价于在创建表时通过STORED AS TEXTFILE语句指定使用文本存储格式。

文本文件格式便于和其他工具（如Pig, Unix文本工具中的grep、sed和awk等）共享数据。同时文本文件也便于查看和编辑。不过，相对于二进制文件，文本文件存储空间要大。正如在第11章中我们讨论过的，可以使用压缩，但是如果使用二进制文件存储格式的话，则既可以节约存储空间，也可以提高I/O性能。

15.3.1 SequenceFile

其中一种存储格式是SequenceFile文件存储格式，在定义表结构时可以通过STORED AS SEQUENCEFILE语句指定。

SequenceFile文件是含有键-值对的二进制文件。当Hive将查询转换成MapReduce job时，对于指定的记录，其取决于使用哪些合适的键-值对。

SequenceFile是Hadoop本身就可以支持的一种标准文件格式，因为它也是在Hive和其他Hadoop相关的工具中共享文件的可以接受的选择。而对于Hadoop生态系统之外的其他工具而言，其并不适合使用。正如我们在第11章中讨论过的，SequenceFile可以在块级别和记录级别进行压缩，这对于优化磁盘利用率和I/O来说非常有意义。同时仍然可以支持按照块级别的文件分割，以方便并行处理。

Hive所支持的另一种高效二进制文件格式就是RCFile。

15.3.2 RCfile

大多数的Hadoop和Hive存储都是行式存储的，在大多数场景下，这是比较高效的。这种高效归根于如下几个原因：大多数的表具有的字段个数都不大（一般就1到20个字段）；对文件按块进行压缩对于需要处理重复数据的情况比较高效，同时很多的处理和调试工具（例如more、head、awk）都可以很好地应用于行式存储的数据。

并非所有的工具和数据存储都是采用行式存储的方式的，对于特定类型的数据和应用来说，采用列式存储有时会更好。例如，如果指定的表具有成百上千个字段，而大多数的查询只需要使用到其中的一

小部分字段，这时扫描所有的行而过滤掉大部分的数据显然是个浪费。然而，如果数据是按照列而不是行进行存储的话，那么只要对其需要的列的数据进行扫描就可以了，这样可以提高性能。

对于列式存储而言，进行压缩通常会非常高效，特别是在这列的数据具有较低计数的时候（只有很少的排重值时）。同时，一些列式存储并不需要物理存储null值的列。

基于这些场景，Hive中才设计了RCFile。

尽管本书提供了非常有价值的信息资源，但是有时查找信息的最好方式还是查看源代码本身。关于Hive中的像RCFile这样的列式存储是如何工作的最好的描述可以在源代码中看到：

```
cd hive-trunk
find . -name "RCFile*"
vi ./ql/src/java/org/apache/hadoop/hive/ql/io/RCFile.java
* <p>
* RCFfile stores columns of a table in a record columnar way. It first
* partitions rows horizontally into row splits. and then it vertically
* partitions each row split in a columnar way. RCFfile first stores the meta
* data of a row split, as the key part of a record, and all the data of a row
* split as the value part.
* </p>
```

Hive功能强大的一个方面体现在在不同的存储格式间转换数据非常地简单。存储信息存放在了表的元数据信息中。当对表执行一个SELECT查询时，以及向其他表中执行INSERT操作时，Hive就会使用这个表的元数据信息中提供的内容，然后自动执行转换过程。这样使用可以有多种选择，而不需要额外的程序来对不同的存储格式进行转换。

可以在创建表时使用ColumnarSerDe、RCFileInputFormat和RCFileOutputFormat：

```
hive> select * from a;
OK
4      5
3      2
Time taken: 0.336 seconds
hive> create table columnTable (key int , value int)
> ROW FORMAT SERDE
> 'org.apache.hadoop.hive.serde2.columnar.ColumnarSerDe'
> STORED AS
> INPUTFORMAT 'org.apache.hadoop.hive.ql.io.RCFileInputFormat'
```

```
> OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.RCFileOutputFormat';
hive> FROM a INSERT OVERWRITE TABLE columnTable SELECT a.col1, a.col2;
```

不可以使用通常可以打开SequenceFile的工具来打开RCFile。不过，Hive提供了一个rcfilecat工具来展示RCFile文件内容：

```
$ bin/hadoop dfs -text /user/hive/warehouse/columntable/000000_0
text: java.io.IOException: WritableName can't load class:
org.apache.hadoop.hive.ql.io.RCFile$KeyBuffer
$ bin/hive --service rcfilecat /user/hive/warehouse/columntable/000000_0
4      5
3      2
```

15.3.3 示例自定义输入格式：DualInputFormat

很多种数据库允许用户执行没有FROM语句的SELECT语句。这可用于执行简单的计算过程，例如 SELECT 1+2。如果Hive不允许执行这种类型的查询的话，那么其实可以通过从某个存在的标准中选取数据，然后将结果限制到一行，来达到同样的效果；或者用户可以创建一个只有一行数据的表。一些数据库提供了一个名为dual的表，其只有一行数据，用来满足这种使用场景。

默认情况下，标准的Hive表使用的输入格式是TextInputFormat。TextInputFormat会对输入的零个或多个划分进行计算。这个框架可以打开这些划分文件，然后使用一个RecordReader来读取划分中的数据。文本中每一行都会成为一条输入记录。为了创建一个适用于dual表的输入格式，我们需要创建一个输入格式，要求其只会返回一个只有一行数据的划分，而不管输入路径是什么^[1]。

在下面这个例子中，DualInputFormat只会返回一个划分：

```
public class DualInputFormat implements InputFormat{
  public InputSplit[] getSplits(JobConf jc, int i) throws IOException {
    InputSplit [] splits = new DualInputSplit[1];
    splits[0]= new DualInputSplit();
    return splits;
  }
  public RecordReader<Text,Text> getRecordReader(InputSplit split, JobConf jc,
    Reporter rprtr) throws IOException {
    return new DualRecordReader(jc, split);
  }
}
```

下面这个例子中划分只有一行数据。不需要进行序列化或反序列化操作：

```
public class DualInputSplit implements InputSplit {  
    public long getLength() throws IOException {  
        return 1;  
    }  
    public String[] getLocations() throws IOException {  
        return new String [] { "localhost" };  
    }  
    public void write(DataOutput d) throws IOException {  
    }  
    public void readFields(DataInput di) throws IOException {  
    }  
}
```

DualRecordReader中有一个布尔值变量hasNext。当第1次调用next()函数后，其值就设置成了false。因此，这个记录读取器返回唯一行，然后就结束了：

```
public class DualRecordReader implements RecordReader<Text,Text>{  
    boolean hasNext=true;  
    public DualRecordReader(JobConf jc, InputSplit s) {  
    }  
    public DualRecordReader(){  
    }  
    public long getPos() throws IOException {  
        return 0;  
    }  
    public void close() throws IOException {  
    }  
    public float getProgress() throws IOException {  
        if (hasNext)  
            return 0.0f;  
        else  
            return 1.0f;  
    }  
    public Text createKey() {  
        return new Text("");  
    }  
    public Text createValue() {  
        return new Text("");  
    }  
    public boolean next(Text k, Text v) throws IOException {  
        if (hasNext){  
            hasNext=false;  
            return true;  
        } else {  
            return hasNext;  
        }  
    }  
}
```

下面我们创建一个使用DualInputFormat输入格式和默认的HiveIgnoreKey TextOutPutFormat输出格式的表，然后从这个表中选取下数据，看其是否只访问一个空行。输入格式的jar包需要包含在HADOOP的lib目录下或者放置在Hive的auxlib目录下。

```
client.execute("add jar dual.jar");
client.execute("create table dual (fake string) "+
  "STORED AS INPUTFORMAT 'com.m6d.dualinputformat.DualInputFormat'"+
  "OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutput Format'");
client.execute("select count(1) as cnt from dual");
String row = client.fetchOne();
assertEquals("1", row);
client.execute("select * from dual");
row = client.fetchOne();
assertEquals( "", row);
```

15.4 记录格式: SerDe

SerDe是序列化/反序列化的简写形式。一个SerDe包含了将一条记录的非结构化字节（它是文件存储的一部分）转化成Hive可以使用的一条记录的过程。可以使用Java来实现SerDe。Hive本身自带了几个内置的SerDe，还有其他一些第三方的SerDe可供选择使用。

在内部，Hive引擎使用定义的InputFormat来读取一行数据记录。这行记录之后会被传递给SerDe.deserialize()方法进行处理。

简单的SerDe除非需要特定的属性时才会完整地实例化某个对象。

下面这个例子使用一个RegexSerDe来处理标准格式的Apache Web日志。这个RegexSerDe是作为Hive分支的标准功能来使用的：

```
CREATE TABLE serde_regex(
  host STRING,
  identity STRING,
  user STRING,
  time STRING,
  request STRING,
  status STRING,
  size STRING,
  referer STRING,
  agent STRING)
ROW FORMAT SERDE 'org.apache.hadoop.hive.contrib.serde2.RegexSerDe'
WITH SERDEPROPERTIES (
  "input.regex" = "([^\"]*) ([^\"]*) ([^\"]*) (-|\\[[^\"]]*\\])"
  "([^\"]*|\"[^\"]*\") (-|[0-9]*) (-|[0-9]*)(?: ([^\"]*|\"[^\"]*\\\")"
  "([^\"]*|\"[^\"]*\\\"))?"
```

```
    "output.format.string" = "%1$s %2$s %3$s %4$s %5$s %6$s %7$s %8$s %9$s"
)
STORED AS TEXTFILE;
```

现在我们可以载入数据，然后查询看看了：

```
hive> LOAD DATA LOCAL INPATH "../data/files/apache.access.log" INTO TABLE
serde_regex;
hive> LOAD DATA LOCAL INPATH "../data/files/apache.access.2.log" INTO TABLE
serde_regex;

hive> SELECT * FROM serde_regex ORDER BY time;
```

(为便于展示，这里有调整正则表达式的显示)

15.5 CSV和TSV SerDe

那么CSV（逗号分隔值）和TSV（回车键分隔符）文件呢？当然，对于如数值数据的简单数据来说，就和我们前面看到的一样，用户只需要使用默认的文件格式并制定字段分隔符即可。不过，这种简单的处理方式既无法处理字符串中自身包含逗号或回车键的情况，也无法处理其他常见的转换，例如，是否对字符串都加引号或不加引号，或者每个文件的第一行是否需要显示“列名数据头”。

首先，如果有列名数据头的话，那么通常将这行数据移除也是可以的。这样有多种第三方SerDe来处理CSV或者TSV文件。对于CSV文件来说，可以考虑使用CSVSerDe：

```
ADD JAR /path/to/csv-serde.jar;

CREATE TABLE stocks(ymd STRING, ...)
ROW FORMAT SERDE 'com.bizo.hive.serde.csv.CSVSerde'
STORED AS TEXTFILE
...;
```

尽管支持TSV应该是与CSV类似的，但是在写本书时还没有合适的第三方TSV SerDe可供使用。

15.6 ObjectInspector

在外壳的下面，Hive使用一个名为ObjectInspector的检查器来将记录转换成Hive可以访问的对象。

15.7 Thing Big Hive Reflection ObjectInspector

Think Big Analytics 创建了一个名为BeansStructObjectInspector的基于Java反射机制的ObjectInspector。使用JavaBean模型的反射机制，任何对象的“属性”信息都可以通过get方法获得，或者作为public成员变量在查询中进行引用。

下面是个介绍如何使用BeansStructObjectInspector的例子：

```
public class SampleDeserializer implements Deserializer {  
    @Override  
    public ObjectInspector getObjectInspector() throws SerDeException {  
        return BeansStructObjectInspector.getBeansObjectInspector(YourObject. class);  
    }  
}
```

15.8 XML UDF

XML天生就是非结构化的，这使得Hive成为XML处理的一个强大的数据库平台。众多原因之一就是大型XML文档解析和处理所需要的复杂性和资源消耗使得Hadoop非常适合作为一个XML数据库平台，因为Hadoop可以并行地处理XML文档，Hive也成为了解决XML相关数据的完美工具。此外，HiveQL原生就支持访问XML的嵌套元素和值，然后进一步地，可以允许对嵌套的字段、值和属性进行连接操作。

XPath（XML路径语言）是一个由W3C创建的用于定位XML文档指定内容的全球性的标准。使用XPath作为XML查询语言的话Hive可以从XML中提取数据并进入Hive系统中进行其他处理，这使得Hive对于XML处理显得极其有用。

XPath将XML文档建模成一个节点树。并提供了访问如字符串、数值和布尔型等基本数据类型的功能。

尽管如Oracle XML DB和MarkLogic等商业解决方案都提供了原生的XML数据库解决方案，但作为开源软件的Hive利用Hadoop的PB级别的并行处理架构给更广泛高效的XML数据库带来了更多的生气。

15.9 XPath相关的函数

Hive中包含有一些从Hive 0.6.0发行版中引入的XPath相关的UDF(见表15-1)。

表15-1 XPath相关的UDF

UDF名称	描述
xpath	返回Hive中的一组字符串数组
xpath_string	返回一个字符串
xpath_boolean	返回一个布尔值
xpath_short	返回一个短整型数值
xpath_int	返回一个整型数值
xpath_long	返回一个长整型数值
xpath_float	返回一个浮点数数值
xpath_double, xpath_number	返回一个双精度浮点数数值

下面的例子展示的是对于常数字符串使用这些函数的情况:

```
hive> SELECT xpath('\'<a><b id="foo">b1</b><b id="bar">b2</b></a>\', \'//@id\'')
   > FROM src LIMIT 1;
[foo", "bar"]

hive> SELECT xpath ('\'<a><b class="bb">b1</b><b>b2</b><b>b3</b><c class=
"bb">c1</c>
<c>c2</c></a>\', \'a/*[@class="bb"]/text()\')'
   > FROM src LIMIT 1;
[b1", "c1"]
```

(为排版好看, 所以将例子中长长的XML字符串进行了转行。)

```
hive> SELECT xpath_double (\'<a><b>2</b><c>4</c></a>\', \'a/b + a/c\')
> FROM src LIMIT 1;
6.0
```

15.10 JSON SerDe

如果用户想使用Hive查询JSON格式的数据，那该怎么办呢？如果每行都只有一个JSON“文件”的话，那么用户可以使用TEXTFILE作为输入输出文件格式，然后使用一个JSON的SerDe来将JSON文档作为一条记录进行解析。

有一个第三方的JSON SerDe，其是在一个Google“编程夏令营”项目中开启的，随后被其他的社区贡献者克隆和开启新的分支。Think Big Analytics也创建了自己的分支并增加了增强功能，后面我们将进行讨论。

在下面例子中，这个SerDe用于从JSON数据中抽出一些域，这些数据假设是来自某个信息系统的。并非要解析出JSON中所有的字段。而那些解析出来的字段都将作为表的字段：

```
CREATE EXTERNAL TABLE messages (
  msg_id      BIGINT,
  tstamp       STRING,
  text         STRING,
  user_id      BIGINT,
  user_name    STRING
)
ROW FORMAT SERDE "org.apache.hadoop.hive.contrib.serde2.JsonSerde"
WITH SERDEPROPERTIES (
  "msg_id"="$ .id",
  "tstamp"="$ .created_at",
  "text"="$ .text",
  "user_id"="$ .user.id",
  "user_name"="$ .user.name"
)
LOCATION '/data/messages';
```

上面语句中的WITH SERDEPROPERTIES是Hive提供的一个功能，允许用户定义一些可以传递给SerDe的属性信息。在合适的情况下SerDe可以读取这些属性。Hive本身并不关心这些属性表达什么含义。

在本例中，这些属性用于将JSON文档和表的字段对应起来。像\$.user.id这样的字符串表示获取每条记录，用\$来表示，然后查找user

的键。本例中也就是假定其是一个JSON map，最后解析出user中id键所对应的值。这里id键所对应的值将对应于表中的user_id字段。

一旦定义好之后，那么用户就可以像通常一样执行查询，根本不用关心查询是如何从JSON中获取数据的！

15.11 Avro Hive SerDe

Avro是一个序列化系统，其主要特点是它是一个进化的模式驱动的二进制数据存储模式。开始的时候，Avro的目标和Hive的目标可能是冲突的，因为它们都期望提供模式或者元数据信息。不过Hive和Hive元数据存储具有可插拔的设计，因此可以支持Avro对模式的推断。

Hive 中的Avro SerDe是由LinkedIn创建的，其提供如下功能。

- ① 从Avro模式中推断出对应的Hive表的模式。
- ② 在一个表中而不是一个指定的模式中读取所有的Avro文件，这得益于Avro的可逆兼容性。
- ③ 支持结构嵌套模式。
- ④ 可以将所有的Avro数据类型转换成等价的Hive类型。大多数的类型可以精确映射，但是一些Avro类型在Hive中并不存在的话，那么将由Hive通过Avro自动进行转换。
- ⑤ 可以解析压缩的Avro文件。
- ⑥ 显式地通过Union[T, null]语句将Avro中可以表示为null的类型转化成T，并在合适的情况下返回null。
- ⑦ 可以将任意的Hive表写成Avro文件。

15.11.1 使用表属性信息定义Avro Schema

如下语句通过指定AvroSerDe、AvroContainerInputFormat和AvroContainerOutputFormat创建了一个Arvo表。Arvo具有其自身的模式定义语言。这个模式定义语言可以使用属性avro.schema.literal以字符串的形式存储在表的属性信息中。模式中指定了3个字段：int类型的number、string类型的firstname和string类型的lastname。

```
CREATE TABLE doctors
ROW FORMAT
SERDE 'org.apache.hadoop.hive.serde2.avro.AvroSerDe'
STORED AS
INPUTFORMAT 'org.apache.hadoop.hive.ql.io.avro.AvroContainerInputFormat'
OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.avro.AvroContainerOutputFormat'
TBLPROPERTIES ('avro.schema.literal'='{
  "namespace": "testing.hive.avro.serde",
  "name": "doctors",
  "type": "record",
  "fields": [
    {
      "name": "number",
      "type": "int",
      "doc": "Order of playing the role"
    },
    {
      "name": "first_name",
      "type": "string",
      "doc": "first name of actor playing role"
    },
    {
      "name": "last_name",
      "type": "string",
      "doc": "last name of actor playing role"
    }
  ]
}');
```

当使用DESCRIBE命令执行查看时，Hive就会显示出这3个字段的名称和类型。从下面的输出信息中我们可以看到输出信息中的第3列显示字段是来自反序列化的。这表明是SerDe自己从字段中返回的信息，而不是存在于元数据存储中的静态数据：

```
hive> DESCRIBE doctors;
number      int      from deserializer
first_name  string   from deserializer
last_name   string   from deserializer
```

15.11.2 从指定URL中定义Schema

同样可以以URL的方式提供模式。可以是HDFS中某个文件的路径或者是指向HTTP服务器的一个链接。通常可以在表属性中设置avro.schema.url的值，同时不设置avro.schema.literal的值。

模式可以是HDFS中的一个文件：

```
TBLPROPERTIES ('avro.schema.url'='hdfs://hadoop:9020/path/to.schema')
```

模式同样可以存储在HTTP服务器上：

```
TBLPROPERTIES ('avro.schema.url'='http://site.com/path/to.schema')
```

15.11.3 进化的模式

随着时间的推移可能会为数据集增加字段或者从数据集中减少一些字段。Avro的设计中有考虑到这个情况。进化的模式是值随着时间而发生改变的模式。Avro允许字段是null。其同样允许如果数据文件中没有定义字段的话就返回指定的缺省值。

例如，如果Avro模式发生了改变，并增加了一个字段，那么在default字段中会提供一个值，如果没有找到这个新增列就返回这个值：

```
{
  "name": "extra_field",
  "type": "string",
  "doc": "an extra field not in the original file",
  "default": "fishfingers and custard"
}
```

15.12 二进制输出

这里有多种二进制输出。我们已经看过文件压缩、sequence文件（压缩的或没有压缩的）以及相关的文件类型。

有时，很有必要读取和写入字节流。例如，用户可能有工具期望获取字节流，而无需任何类型的字段分隔符，而且用户既希望使用Hive来为这些工具生成合适的文件，又希望通过Hive来查询这些文件。用户可能也希望使用简洁的二进制格式存储数值而不是使用

像“5034223，”这样的需要更多存储空间的字符串来进行存储。一个常用的例子就是查询tcpdump命令的输出来分析网络行为。

下面的表期望自己的文件是文本文件格式的，但是其可以将查询结果按二进制数据流方式进行写操作：

```
CREATE TABLE binary_table (num1 INT, num2 INT)
ROW FORMAT SERDE 'org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe'
WITH SERDEPROPERTIES ('serialization.last.column.takes.rest'='true')
STORED AS
INPUTFORMAT 'org.apache.hadoop.mapred.TextInputFormat'
OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveBinaryOutputFormat';
```

下面是个SELECT TRANSFORM查询的例子，其从表src中读取二进制数据流，然后直接将数据流传递给shell命令cat，最后将结果覆盖，写入到表destination1中：

```
INSERT OVERWRITE TABLE destination1
SELECT TRANSFORM(*)
USING 'cat' AS mydata STRING
ROW FORMAT SERDE 'org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe'
WITH SERDEPROPERTIES ('serialization.last.column.takes.rest'='true')
RECORDREADER 'org.apache.hadoop.hive.ql.exec.BinaryRecordReader'
FROM src;
```

[1]可以通过如下链接获取到DualInputFormat的源码：
<https://github.com/edwardcapriolo/DualInputFormat>。

第16章 Hive的Thrift服务

Hive具有一个可选的组件叫做HiveServer或者HiveThrift，其允许通过指定端口访问Hive。Thrift是一个软件框架，其用于跨语言的服务开发。关于Thrift，可以通过链接<http://thrift.apache.org/> 获得更详细的介绍。Thrift允许客户端使用包括Java、C++、Ruby和其他很多种语言，通过编程的方式远程访问Hive。

访问Hive的最常用的方式就是通过CLI进行访问。不过，CLI的设计使其不便于通过编程的方式进行访问。CLI是胖客户端，其需要本地具有所有的Hive组件，包括配置，同时还需要一个Hadoop客户端及其配置。同时，其可作为HDFS客户端、MapReduce客户端以及JDBC客户端（用于访问元数据库）进行使用。即使客户端安装是成功的，但是配置所有的网络访问还是会比较困难的，特别是对于不同网段或跨数据中心的情况。

16.1 启动Thrift Server

如果想启用HiveServer，可以在后台启动执行这个Hive服务：

```
$ cd $HIVE_HOME
$ bin/hive --service hiveserver &
Starting Hive Thrift Server
```

检查HiveServer是否启动成功的最快捷方法就是使用netstat命令查看10,000端口是否打开并监听连接：

```
$ netstat -nl | grep 10000
tcp  0  0 ::1:10000      ::*:          LISTEN
```

（为排版方便，上面例子中去除掉了一些空格。）正如前面所提到过的，HiveServer使用Thrift提供服务。Thrift提供了一个接口语言。通过这些接口，Thrift编译器可以产生创建网络RPC的多种程序语言的客户端的代码。因为Hive是使用Java编写的，而且Java的字节码是跨平台的，Thrift服务的客户端包含在了Hive发行版中。使用这些客户端的

方式就是在IDE中开启一个Java工程，然后载入这些库，或者通过Maven获取这些库。

16.2 配置Groovy使用HiveServer

为了讲解这个例子，我们将先对使用到Groovy进行介绍。Groovy是一个对于Java虚拟机来说敏捷的动态的程序语言。Groovy是进行原型设计的理想选择，因为其很好地兼容Java，并提供了一个所见即所得的（REPL）的编码过程：

```
$ curl -o http://dist.groovy.codehaus.org/distributions/groovy-binary-1.8.6.zip  
$ unzip groovy-binary-1.8.6.zip
```

下载好压缩包后，通过修改groovy-starter.conf文件，将所有的Hive JAR文件加入到Groovy的classpath路径中。这将允许Groovy直接和Hive进行交互而无需人为地在每个会话中载入相关的JAR文件。

```
# load required libraries  
load !{groovy.home}/lib/*.jar  
  
# load user specific libraries  
load !{user.home}/.groovy/lib/*.jar  
  
# tools.jar for ant tasks  
load ${tools.jar}  
  
load /home/edward/hadoop/hadoop-0.20.2_local/*.jar  
load /home/edward/hadoop/hadoop-0.20.2_local/lib/*.jar  
load /home/edward/hive-0.9.0/lib/*.jar
```



提示

Groovy有一个@grab标注，用于从Maven网站库中获取到JAR文件，但是到目前为止Hive的一些打包问题使得这种方式无法正常工作。

Groovy在分支版本中提供了bin/groovysh这个shell脚本。这个脚本提供了一个REPL用于交互式编程。Groovy代码和Java代码类似，尽管其确实有其他如终止功能的形式。大多数情况下，用户可以像写Java一样编写Groovy代码。

16.3 连接到HiveServer

从这个REPL中，导入Hive和Thrift相关的类。这些类用于连接到Hive，及创建一个HiveClient实例。HiveClient含有用户和Hive交互所需要的常用方法：

```
$ $HOME/groovy/groovy-1.8.0/bin/groovysh
Groovy Shell (1.8.0, JVM: 1.6.0_23)
Type 'help' or '\h' for help.
groovy:000> import org.apache.hadoop.hive.service.*;
groovy:000> import org.apache.thrift.protocol.*;
groovy:000> import org.apache.thrift.transport.*;
groovy:000> transport = new TSocket("localhost", 10000);
groovy:000> protocol = new TBinaryProtocol(transport);
groovy:000> client = new HiveClient(protocol);
groovy:000> transport.open();
groovy:000> client.execute("show tables");
```

16.4 获取集群状态信息

这个getClusterStatus方法会从Hadoop的JobTracker中获取信息。其可用于获取收集监控信息也可用于寻找空闲时间来提交任务：

```
groovy:000> client.getClusterStatus()
====> HiveClusterStatus(taskTrackers:50, mapTasks:52, reduceTasks:40,
maxMapTasks:480, maxReduceTasks:240, state:RUNNING)
```

16.5 结果集模式

在执行一个查询后，用户可以通过getSchema()方法获取到结果集的schema。如果用户在执行一个查询前调用这个方法的话，那么其将返回一个null schema：

```
groovy:000> client.getSchema()
====> Schema(fieldSchemas:null, properties:null)
groovy:000> client.execute("show tables");
====> null
groovy:000> client.getSchema()
====> Schema(fieldSchemas:[FieldSchema(name:tab_name, type:string,
comment:from deserializer)], properties:null)
```

16.6 获取结果

当执行查询后，用户可以通过`fetchOne()`方法获取到结果集。并不建议通过Thrift接口来获取数据量大的结果。不过，其确实提供了几种方法来通过单向指针获取数据。其中`fetchOne()`方法用于获取一行数据：

```
groovy:000> client.fetchOne()  
====> cookjar_small
```

除了一次获取一行数据这种方式外，还可以通过`fetchALL()`方法以字符数组的形式获取整个结果集：

```
groovy:000> client.fetchAll()  
====> [macetest, missing_final, one, time_to_serve, two]
```

同时还提供了`fetchN`方法，其用于一次获取 N 行结果。

16.7 获取执行计划

执行过一个查询之后，就可以使用`getQueryPlan()`方法来获取关于这个查询的状态信息。信息内容包括计数器的信息和job的状态信息：

```
groovy:000> client.execute("SELECT * FROM time_to_serve");  
====> null  
groovy:000> client.getQueryPlan()  
====> QueryPlan(queries:[Query(queryId:hadoop_20120218180808_...-aedf367 ea2f3,  
queryType:null, queryAttributes:{queryString=SELECT * FROM time_to_serve},  
queryCounters:null, stageGraph:Graph(nodeType:STAGE, roots:null,  
adjacencyList:null), stageList:null, done:true, started:true)],  
done:false, started:false)
```

(这里省略了一长串的数字。)

16.8 元数据存储方法

Hive通过Thrift提供Hive元数据存储的服务。通常来说，用户应该不能够直接调用元数据存储方法来直接对元数据进行修改，而应该通过HiveQL语言让Hive来执行这样的操作。用户应该只能通过利用只读方法来获取表的元数据信息。例如，可以使用`get_partition_names(String, String, short)`方法来确认查询可以使用的分区有哪些：

```
groovy:000> client.get_partition_names("default", "fracture_act", (short)0)
[ hit_date=20120218/mid=001839, hit_date=20120218/mid=001842,
hit_date=20120218/mid=001846 ]
```

重要的是，要记住，尽管元数据存储API的变化相对是比较稳定的，但是，包括它们的签名和目的，在不同的发行版中都可能会变化。Hive试图在HiveQL语言中保持兼容性，这样对于这些级别的变化就会掩盖掉了。

表检查器例子

以编程的方式来访问元数据存储的能力提供了部署过程中的监控和执行条件的能力。例如，可以通过编写一个检查器来确定是否所有的表都使用了压缩，或者所有以zz开头的表保存时间不能超过10天。如果有必要的话，这些小的“Hive小程序”可以快速地编写完成并可以远程执行。

查找非外部表的表

默认情况下，管理表会在数据仓库目录下存储表数据，这个目录通常默认为/user/hive/warehouse。而通常情况下，外部表不会使用这个目录，但是也并非就不能使用这个目录存储外部表数据。通过增加一个规则，要求管理表必须存放数据到数据仓库目录下将会有利于保持环境的清晰。

在接下来的这个程序中，最外层的循环对get_all_databases()方法的返回结果列表进行迭代。而内层的循环对get_all_tables(database)方法的结果列表进行迭代。方法get_table(data base, table)的返回结果Table对象包含了这个表的所有元数据信息。我们可以检查表的存储路径和表的类型是否是MANAGED_TABLE。外部表的表类型是EXTERNAL。最终会返回一组“不符合规则的”表名，用列表bad表示：

```
public List<String> check(){
  List<String> bad = new ArrayList<String>();
  for (String database: client.get_all_databases() ){
    for (String table: client.get_all_tables(database) ){
      try {
        Table t = client.get_table(database,table);
        URI u = new URI(t.getSd().getLocation());
        if (t.getTableType().equals("MANAGED_TABLE") &&
```

```

        ! u.getPath().contains("/user/hive/warehouse") ){
        System.out.println(t.getTableName()
            + " is a non external table mounted inside /user/hive/ warehouse" );
        bad.add(t.getTableName());
    }
} catch (Exception ex){
    System.err.println("Had exception but will continue " +ex);
}
}
}
return bad;
}
}

```

16.9 管理HiveServer

Hive CLI会在本地创建如文件名为.hivehistory这样的部件，以及会在/tmp目录和hadoop.tmp.dir目录下创建一些条目。因为HiveServer成为了Hadoop job开启执行的地方，所以在部署的时候需要注意几个注意事项。

16.9.1 生产环境使用HiveServer

除了在本地安装完整的Hive客户端，还可以通过HiveServer服务来提交job。不过如果在生产环境下使用HiveServer的话，那么确实还需要解决一些额外的问题。通常客户端机器需要进行的形成执行计划和管理task的工作现在需要由服务端来完成了。如果用户同时执行多个客户端的话，那么就会对于单个HiveServer造成太大的压力。一种简单的解决办法就是使用TCP负载均衡或者通过代理的方式为一组后面的服务器进行均衡连接。

有多种方式来进行TCP负载均衡，用户需要咨询下网络管理员寻求最好的解决方案。我们建议通过haproxy工具来对众多的ThriftServer服务器均衡连接。

首先，需要列举出所有的物理ThriftServer服务器，并记录代理对应的虚拟服务器（见表16-1和表16-2）。

表16-1 物理服务器配置

短域名	主机名和端口

短域名	主机名和端口
HiveService1	hiveserver1.example.pvt:10000
HiveService2	hiveserver2.example.pvt:10000

表16-2 代理配置

主机名	IP地址
hiveprimary.example.pvt	10.10.10.100

安装ha-proxy软件(也就是HAP)。对于不同的操作系统和分发版本，安装步骤可能有所不同。下面的例子中展示的是RHEL/CENTOS分发版的安装命令：

```
$sudo yum install haproxy
```

按照前面的清单来完成配置文件：

```
$ more /etc/haproxy/haproxy.cfg
listen hiveprimary 10.10.10.100:10000
balance leastconn
mode tcp
server hivethrift1 hiveservice1.example.pvt:10000 check
server hivethrift2 hiveservice1.example.pvt:10000 check
```

通过系统的init脚本来启动HAP。一旦确认可以正常执行后，那么就可以使用chkconfig命令将其加入到默认的系统启动过程中：

```
$ sudo /etc/init.d/haproxy start
$ sudo chkconfig haproxy on
```

16.9.2 清理

Hive提供了配置变量hive.start.cleanup.scratchdir，默认值是false。将这个属性设置为true的话，那么就会在每次重启HiveServer服务时清理掉临时目录：

```
<property>
  <name>hive.start.cleanup.scratchdir</name>
  <value>true</value>
  <description>To clean up the Hive scratchdir while
  starting the Hive server</description>
</property>
```

16.10 Hive ThriftMetastore

典型情况下，Hive会话会直接连接到一个JDBC数据库，这个数据库用作元数据存储数据库。Hive提供了一个可选的组件名为ThriftMetastore。在这种设置下，Hive客户端会连接到ThriftMetastore，而且会和JDBCMetastore进行通信。大多数的部署是不需要这个组件的。对于那些非Java客户端而又需要获取到元数据存储信息时才会使用这个组件。使用这种元数据库服务需要2个单独的配置。

16.10.1 ThriftMetastore 配置

ThriftMetastore应该和实际使用JDBC的元数据存储进行通信，然后再通过如下方法启动metastore：

```
$ cd ~
$ bin/hive --service metastore &
[1] 17096
Starting Hive Metastore Server
```

使用netstat命令来确认元数据服务启动并正在执行：

```
$ netstat -an | grep 9083
tcp 0 0 :::9083      ::::*      LISTEN
```

16.10.2 客户端配置

像CLI这样的客户端需要直接和元数据存储通信：

```
<property>
  <name>hive.metastore.local</name>
  <value>false</value>
  <description>controls whether to connect to remove metastore server
  or open a new metastore server in Hive Client JVM</description>
</property>

<property>
  <name>hive.metastore.uris</name>
  <value>thrift://metastore_server:9083</value>
  <description>controls whether to connect to remove metastore server
  or open a new metastore server in Hive Client JVM</description>
</property>
```

这个变化对于用户来说是透明的。不过，对于Hadoop安全来说这里还是有细微的差别，而且需要以用户的身份信息来执行元数据存储相关的操作。

第17章 存储处理程序和NoSQL

存储处理程序是一个结合InputFormat、OutputFormat、SerDe和Hive需要使用的特定的代码，来将外部实体作为标准的Hive表进行处理的整体。这样无论表是以文本文件的方式存储在Hadoop中，还是以列族的方式存储在如*Apache HBase*、*Apache Cassandra*和*Amazon DynamoDB*这样的NoSQL数据库中，用户都可以无缝地直接执行查询，解决问题。存储处理程序不仅限于NoSQL数据库，可以为多种类别的数据存储设计一个数据存储处理程序。



提示

对于特定的存储处理程序可能只需实现其中的某些功能。例如，一个给定的存储处理程序可能允许只读访问权限或实施其他一些限制。

存储处理程序提供了一个ETL的简化系统。例如，一个Hive查询可以从一个sequence file存储格式的表中选取数据，也可以进行输出。

17.1 Storage Handler Background

Hadoop中有一个名为InputFormat的抽象接口类，其可以将来自不同源的数据格式化成可以作为job输入的格式。TextInputFormat就是InputFormat的一个具体实现。其会提供给Hadoop关于如何将给定文件路径下的文件分割成多个划分，然后分发给多个task进行处理的信息，而且还提供了一个RecordReader接口，该接口提供了用于从每个划分中读取数据的方法。

Hadoop同是还提供了一个名为OutputFormat的抽象接口，其会获取到一个job的输出，然后将这个输出输入到一个实体中。TextOutputFormat就是OutputFormat的一个具体实现。其可以持续地将结果输入到一个存储在HDFS或本地文件系统中的文件中。

在Hadoop中输入和输出是物理文件的情况很正常，不过InputFormat和OutputFormat抽象接口可被用于从其他数据源（包括关系型数据库、NoSQL存储（如Cassandra）或HBase，以及其他任何可通过InputFormat或者OutputFormat进行设计实现的存储）中读取和存放数据。

在“HiveQL”那一章中，我们展示了使用Java代码编写的Word Count的例子，然后展示了在Hive中等价的实现方式。Hive中的抽象如表、类型、行格式以及其他元数据都用于Hive理解源数据。一旦Hive了解了源数据的描述信息，那么查询引擎就可以使用熟悉的HiveQL操作符来处理数据。

很多的NoSQL数据库都使用传统适配器实现了Hive连接器。

17.2 HiveStorageHandler

HiveStorageHandler是Hive用于连接如HBase、Cassandra等类似的NoSQL存储的主要接口。检查下接口可以发现需要定义一个定制的InputFormat、一个OutputFormat以及SerDe。存储处理程序负责从底层存储子系统中读取或写入数据。这就转变成通过写SELECT查询读取数据系统中的数据，以及通过如reports这样的操作将数据写入到数据系统。

当在NoSQL数据库之上执行Hive查询时，NoSQL系统的资源消耗、执行效率要比常规的基于HDFS的Hive和MapReduce job要慢。其中一部分原因源于服务器的socket连接资源消耗和对底层多个文件的合并过程，而从HDFS中典型的访问是完全顺序I/O，顺序I/O在现代磁盘上是非常快的。

在一个系统整体架构中将NoSQL数据库和Hadoop结合使用的一个通用技术就是使用NoSQL数据库集群来进行实时处理工作，而利用Hadoop集群进行非实时面向批处理的工作。如果NoSQL系统是主数据存储，而其数据又需要通过Hadoop的批处理job进行查询的话，批量导出是一个将NoSQL数据导入到HDFS文件中的高效的方式。一旦HDFS中的文件通过导出生成后，就可以以最大效率执行批处理Hadoop job。

17.3 HBase

如下例子展示了如何使用HiveQL创建一个指向HBase表的Hive表：

```
CREATE TABLE hbase_stocks(key INT, name STRING, price FLOAT)
STORED BY 'org.apache.hadoop.hive.hbase.HBaseStorageHandler'
WITH SERDEPROPERTIES ("hbase.columns.mapping" = ":key,stock:val")
TBLPROPERTIES ("hbase.table.name" = "stocks");
```

如果想创建一个指向一个已经存在的HBase表的Hive表的话，那么就必须使用CREATE EXTERNAL TABLE这个HiveQL语句：

```
CREATE EXTERNAL TABLE hbase_stocks(key INT, name STRING, price FLOAT)
STORED BY 'org.apache.hadoop.hive.hbase.HBaseStorageHandler'
WITH SERDEPROPERTIES ("hbase.columns.mapping" = "cf1:val")
TBLPROPERTIES("hbase.table.name" = "stocks");
```

对于一个指定的Hive查询，不需要扫描整个HBase表，通过过滤下推裁剪将会得到返回给Hive的行数据。

可以进行谓词下推的类型如下。

- ① $\text{key} < 20$ 。
- ② $\text{key} = 20$ 。
- ③ $\text{key} < 20$ ，而且 $\text{key} > 10$ 。

其他的复杂类型的谓词都会忽略掉而不会启用下推功能。

下面是一个简单的例子，其先创建了一个简单的表，然后对这个表进行的查询语句将会使用到过滤条件下推的功能。需要注意的是下推的总是HBase的键，而非列组中的列值。

```
CREATE TABLE hbase_pushdown(key int, value string)
STORED BY 'org.apache.hadoop.hive.hbase.HBaseStorageHandler'
WITH SERDEPROPERTIES ("hbase.columns.mapping" = ":key,cf:string");

SELECT * FROM hbase_pushdown WHERE key = 90;
```

如下这个查询不会查询下推，因为其过滤条件中包含有OR操作符。

```
SELECT * FROM hbase_pushdown
WHERE key <= '80' OR key >= '100';
```

和HBase结合使用的Hive支持HBase表和HBase表的连接操作，也支持HBase表和非HBase表的连接操作。

默认情况下，下推优化是开启的，不过可以通过如下命令将此功能关闭：

```
set hive.optimize.ppd.storage=false;
```

当将Hive中的数据导入到HBase中时，需要注意，HBase要求键是排重后唯一的，而Hive并无此要求。

下面是一些Hive和HBase列映射需要注意的问题。

- ① 没有访问HBase行时间戳的方式，只会返回最新版本的行。
- ② HBase的键必须进行显式定义。

17.4 Cassandra

Cassandra已经采用和HBase中类似的实现方式实现了HiveStorageHandler接口。这种实现方式最先是在Brisk项目中的Datastax中使用的。

这个模式非常简单，一个Cassandra列族和一个Hive表映射起来。同样地，Cassandra列名和Hive列名直接映射起来。

17.4.1 静态列映射 (Static Column Mapping)

当用户指定了Cassandra中的哪些列期望和Hive列进行映射时使用静态列存储非常有用。下面的例子中，首先创建了一个Hive外部表，其和一个已存在的Cassandra键空间及列族相映射：

```

CREATE EXTERNAL TABLE Weblog(useragent string, ipaddress string, timestamp string)
STORED BY 'org.apache.hadoop.hive.cassandra.CassandraStorageHandler'
WITH SERDEPROPERTIES (
  "cassandra.columns.mapping" = ":key,user_agent,ip_address,time_stamp")
TBLPROPERTIES (
  "cassandra.range.size" = "200",
  "cassandra.slice.predicate.size" = "150" );

```

17.4.2 为动态列转置列映射

某些Cassandra使用场景会用到动态列。这种使用场景是某个指定列组没有固定的、已命名的列，而是由列的行键代表某片数据。这常用于时间序列数据，其中列名代表时间，而列值代表那个时间的值。如果列名是已知的话，或者用户需要检索所有值时，这也是很有用的。

```

CREATE EXTERNAL TABLE Weblog(useragent string, ipaddress string, timestamp string)
STORED BY 'org.apache.hadoop.hive.cassandra.CassandraStorageHandler'
WITH SERDEPROPERTIES (
  "cassandra.columns.mapping" = ":key,:column,:value");

```

17.4.3 Cassandra SerDe Properties

表17-1中所介绍的属性可以在WITH SERDEPROPERTIES语句中进行定义。

表17-1 Cassandra SerDe存储控制器属性

名称	描述
cassandra.cloumns.mapping	将Hive的列和Cassandra的列映射起来
cassandra.cf.name	Cassandra中的列族名
cassandra.host	要连接的Cassandra节点IP
cassandra.port	Cassandra RPC端口， 默认是9160

名称	描述
cassandra.partitioner	分区器, 默认是RandomPartitioner

表17-2中所介绍的属性可以在TBLPROPERTIES语句中进行定义。

表17-2 Cassandra表属性

属性名	描述
cassandra.ks.name	Cassandra 键空间名称
cassandra.ks.repfactor	Cassandra冗余因子, 默认是1
cassandra.ks.strategy	冗余策略, 默认是SimpleStrategy
cassandra.input.split.size	MapReduce划分大小, 默认是64*1024
cassandra.range.size	MapReduce批处理范围大小, 默认是1000
cassandra.slice.predicate.size	MapReduce片推测大小, 默认是1000

17.5 DynamoDB

Amazon的Dynamo是最先推出的NoSQL数据库之一。Dynamo的设计影响了很多其他的数据库, 包括Cassandra和HBase。尽管其有很大的影响力, 但是Dynamo目前还仅限制在Amazon内部进行使用。

Amazon发布了另一款受Dynamo影响的数据库, 这个数据库被称为DynamoDB。

DynamoDB属于键-值数据库中的一种。在DynamoDB中，表就是一组元素（item）的集合，而且其中必需要有一个主键。一个元素（item）包含有一个键和任意数量的属性值。不同的元素（item）可以具有不同的属性集。

用户可以通过Hive查询DynamoDB中的表，而且用户可以迁移出数据或者导入数据到S3中。下面是一个关于股票的Hive表的例子，这个表底层其实是一张DynamoDB表：

```
CREATE EXTERNAL TABLE dynamo_stocks(
  key INT, symbol STRING,
  ymd STRING, price FLOAT)
STORED BY
  'org.apache.hadoop.hive.dynamodb.DynamoDBStorageHandler'
TBLPROPERTIES (
  "dynamodb.table.name" = "Stocks",
  "dynamodb.column.mapping" =
  "key:Key,symbol:Symbol,
  ymd:YMD,price_close:Close");
```

关于DynamoDB，可以通过如下链接获取更多信息：
<http://aws.amazon.com/dynamodb/>。

第18章 安全

在了解Hive的安全机制之前，我们需要首先清楚Hadoop的安全机制以及Hadoop的历史。Hadoop起源于Apache Nutch的子项目。在那个时期以及其整个早期原型时期，功能性需求比安全性需求优先级要高。分布式系统的安全问题要比正常情况下更加复杂，因为不同机器上的多个组件需要相互进行通信。

在如v0.20.205发行版之前的非安全Hadoop版本中，是通过调用本地的whoami脚本获取用户名的。用户可以自由地通过设置FSShell命令（文件系统命令）中的hadoop.job.ugi属性来改变这个参数值。Map或者Reduce任务（task）都以相同的系统用户（通常用户名是hadoop或者mapred）在Task-Tracker节点上执行任务。同样地，Hadoop组件通常要监听数值比较大的端口。通常情况下，都是以非特权用户来执行的（例如，非root用户的其他用户）。

最近对于Hadoop的安全引入了多个变化，其中主要是对于Kerberos安全认证的支持，还包含其他一些问题的修复。Kerberos允许客户端和服务端相互认证。客户端的每次请求中都会带有凭证（ticket）信息。在TaskTracker上执行的任务（task）都是由执行任务（job）的用户来执行的。用户无法通过设置hadoop.job.ugi属性的值来模拟其他人来执行任务。为了达到这个目的，所有的Hadoop组件从头到尾都要使用Kerberos安全认证。

Hive在Hadoop引入Kerberos支持之前就已经存在了，而且Hive目前还没有完全和Hadoop的安全改变相融合。例如，Hive元数据存储连接可能是直接连接到一个JDBC数据库或者是通过Thrift进行连接，这些都要使用用户的身份进行各种操作。像HiveService这样的基于Thrift的组件还是要冒充他人来执行。Hadoop的文件用户权限模型（也就是对于一个文件分为用户、组和其他3层权限）和很多其他数据库中用户权限模型具有很大的差异，数据库中通常是使用对表行或者字段级别进行授权和权限回收操作来进行权限控制的。

本章试图强调在安全和非安全Hadoop版本中Hive的组件操作的不同点。关于Hadoop的安全特性的详细介绍，请参考 Tom White

(O'Reilly) 所著的《Hadoop编程指南》一书。



警告

Hadoop中的安全支持仍然是相对比较新且处于进化中的。Hive中有些部分还是无法和Hadoop的安全支持相融合的。本节所讨论的内容总结了当前Hive安全的状况，但这并非是最终状况。

关于Hive安全的更多内容，可以参考Hive的安全wiki页面：<https://cwiki.apache.org/confluence/display/Hive/Security>。同时，和本书中其他章节不同的是，我们会要求用户查看更多相关的JIRA获取更多信息。

18.1 和Hadoop安全功能相结合

Hive v0.7.0版本增加了和Hadoop安全功能的结合^[1]，这意味着，例如，当Hive提交任务到安全集群的JobTracker上时，其将使用合适的认证处理过程。用户权限可以被授予也可以被回收，这个下面我们将进行讨论。

不过在Thrift和其他组件中仍存在着几个已知的安全漏洞，这些在Hive的安全wiki页面上有列举出来。

18.2 使用Hive进行验证

如果文件和文件夹是多个用户共同拥有的话，那么文件的权限设置就变的非常重要。HDFS中文件目录权限和Unix中的模式非常相似，都包含有3层：用户、组和其他。同时具有3种权限：可读、可写和可执行。Hive中有一个配置变量hive.files.umask.value来定义对于新创建的文件设置的默认权限的umask值，也就是掩码字节数。

```
<property>
  <name>hive.files.umask.value</name>
  <value>0002</value>
  <description>The dfs.umask value for the hive created folders</description>
</property>
```

同时，当属性hive.metastore.authorization.storage.checks的值为true时，如果用户没有权限删除表底层的文件，Hive就会阻止用户来删除这样的表。这个参数的默认值是false，而其应该是设置为true的：

```
<property>
  <name>hive.metastore.authorization.storage.checks</name>
  <value>true</value>
  <description>Should the metastore do authorization checks against
    the underlying storage for operations like drop-partition (disallow
    the drop-partition if the user in question doesn't have permissions
    to delete the corresponding directory on the storage).</description>
</property>
```

当在安全模式下执行时，Hive元数据存储要尽可能地将hive.metastore.execute.setugi设置为true。

```
<property>
  <name>hive.metastore.execute.setugi</name>
  <value>false</value>
  <description>In unsecure mode, setting this property to true will
  cause the metastore to execute DFS operations using the client's
  reported user and group permissions. Note that this property must
  be set on both the client and server sides. Further note that its
  best effort. If client sets it to true and server sets it to false,
  client setting will be ignored.</description>
</property>
```

可以在如下JIRA中获取更详细的信息：
<https://issues.apache.org/jira/browse/HIVE-842>，“Hive中安全任务架构”。

18.3 Hive中的权限管理

Hive v0.7.0版本中同时增加了通过HiveQL进行授权设置的功能[2]。默认情况下，授权模块是不开启的，需要将如下的属性设置为true，才能开启授权：

```
<property>
  <name>hive.security.authorization.enabled</name>
  <value>true</value>
  <description>Enable or disable the hive client authorization</description>
</property>
<property>
  <name>hive.security.authorization.createtable.owner.grants</name>
  <value>ALL</value>
  <description>The privileges automatically granted to the owner whenever
```

```
a table gets created. An example like "select,drop" will grant select  
and drop privilege to the owner of the table</description>  
</property>
```

默认情况下，`hive.security.authorization.createTable.owner.grants`的值是`null`，这使得用户无法访问自己的表。因此，我们也要给予表创建者对应的权限才能访问自己创建的表。



警告

当前用户是可以通过`set`命令来将相关的属性设置为`false`来关闭权限认证的。

18.3.1 用户、组和角色

可以对用户（`user`） 、组（`group`） 或者角色（`role`） 授予权限或者收回权限。我们将逐步演示对这些实体的授权过程。

```
hive> set hive.security.authorization.enabled=true;  
hive> CREATE TABLE authorization_test (key int, value string);  
Authorization failed:No privilege 'Create' found for outputs { database:default}.  
Use show grant to get more details.
```

我们已经看到，我们使用的用户没有在`default`数据库下创建表的权限。我们可以对多个实体进行授权。第一个实体就是用户

（`user`），`Hive`中的用户就是用户的系统用户名。我们可以确定其名称，并按照如下语句将在`default`数据库下的创建表（`create`）权限授予这个用户：

```
hive> set system:user.name;  
system:user.name=edward  
hive> GRANT CREATE ON DATABASE default TO USER edward;  
hive> CREATE TABLE authorization_test (key INT, value STRING);
```

我们可以通过`SHOW GRANT`命令查看授权结果情况：

```
hive> SHOW GRANT USER edward ON DATABASE default;  
database          default  
principalName    edward
```

principalType	USER
privilege	Create
grantTime	Mon Mar 19 09:18:10 EDT 2012
grantor	edward

在用户很多同时表也很多的情况下，对于用户级别的权限授予将会给运维上带来高成本。一个更好的选择就是基于组（group）级别的权限授予。Hive中组和用户的主POSIX组是等价的：

```
hive> CREATE TABLE authorization_test_group(a int,b int);

hive> SELECT * FROM authorization_test_group;
Authorization failed:No privilege 'Select' found for inputs
{ database:default, table:authorization_test_group, columnName:a}.
Use show grant to get more details.

hive> GRANT SELECT on table authorization_test_group to group edward;

hive> SELECT * FROM authorization_test_group;
OK
Time taken: 0.119 seconds
```

如果用户（user）和组（group）仍不够灵活的话，那么可以使用角色（role）。用户可以放置在角色中同时可以为角色进行授权。角色是非常灵活的，因为和组不一样，组是由系统外部进行控制的，而角色是由Hive内部进行控制的：

```
hive> CREATE TABLE authentication_test_role (a int , b int);

hive> SELECT * FROM authentication_test_role;
Authorization failed:No privilege 'Select' found for inputs
{ database:default, table:authentication_test_role, columnName:a}.
Use show grant to get more details.

hive> CREATE ROLE users_who_can_select_authentication_test_role;

hive> GRANT ROLE users_who_can_select_authentication_test_role TO USER edward;

hive> GRANT SELECT ON TABLE authentication_test_role
> TO ROLE users_who_can_select_authentication_test_role;

hive> SELECT * FROM authentication_test_role;
OK
Time taken: 0.103 seconds
```

18.3.2 Grant 和 Revoke权限

表18-1 列举出了可以配置的权限。

表18-1 权限

名称	描述
ALL	赋予所有的权限
ALTER	有修改表结构的权限
CREATE	有创建表的权限
DROP	有删除表或表中的分区的权限
INDEX	创建表索引的权限 (注意: 当前并未实现)
LOCK	开启并发后, 锁定和解锁表的权限
SELECT	查询表或者分区中数据的权限
SHOW_DATABASE	查看所有数据库的权限
UPDATE	向表或者分区中插入或加载数据的权限

下面这个例子演示了如何使用CREATE权限:

```

hive> SET hive.security.authorization.enabled=true;
hive> CREATE DATABASE edsstuff;
hive> USE edsstuff;
hive> CREATE TABLE a (id INT);
Authorization failed:No privilege 'Create' found for outputs
{ database:edsstuff}. Use show grant to get more details.
hive> GRANT CREATE ON DATABASE edsstuff TO USER edward;
hive> CREATE TABLE a (id INT);
hive> CREATE EXTERNAL TABLE ab (id INT);

```

同样地，我们可以通过如下命名授予ALTER权限：

```
hive> ALTER TABLE a REPLACE COLUMNS (a int , b int);
Authorization failed:No privilege 'Alter' found for inputs
{ database:edsstuff, table:a}. Use show grant to get more details.

hive> GRANT ALTER ON TABLE a TO USER edward;

hive> ALTER TABLE a REPLACE COLUMNS (a int , b int);
```

需要注意的是，对于如下这种为分区表新增分区的操作是不需要ALTER权限的：

```
hive> ALTER TABLE a_part_table ADD PARTITION (b=5);
```

往表中加载数据的话需要使用UPDATE权限：

```
hive> LOAD DATA INPATH '${env:HIVE_HOME}/NOTICE'
> INTO TABLE a_part_table PARTITION (b=5);
Authorization failed:No privilege 'Update' found for outputs
{ database:edsstuff, table:a_part_table}. Use show grant to get more details.

hive> GRANT UPDATE ON TABLE a_part_table TO USER edward;

hive> LOAD DATA INPATH '${env:HIVE_HOME}/NOTICE'
> INTO TABLE a_part_table PARTITION (b=5);
Loading data to table edsstuff.a_part_table partition (b=5)
```

删除表或者分区需要DROP权限：

```
hive> ALTER TABLE a_part_table DROP PARTITION (b=5);
Authorization failed:No privilege 'Drop' found for inputs
{ database:edsstuff, table:a_part_table}. Use show grant to get more details.
```

从表或者分区中查询数据的话需要SELECT权限：

```
hive> SELECT id FROM a_part_table;
Authorization failed:No privilege 'Select' found for inputs
{ database:edsstuff, table:a_part_table, columnName:id}. Use show
grant to get more details.

hive> GRANT SELECT ON TABLE a_part_table TO USER edward;

hive> SELECT id FROM a_part_table;
```



警告

目前GRANT SELECT(COLUMN)这个操作语法是通过的，不过实际不会执行。

用户同样可以通过如下命令授予全部的权限：

```
hive> GRANT ALL ON TABLE a_part_table TO USER edward;
```

18.4 分区级别的权限

Hive中分区表非常常见。默认情况下，是在表级别授予权限的。不过，同样可以在分区级别进行权限授予。为达到这个目标，只需要将表属性PARTITION_LEVEL_PRIVILEGE设置为TRUE即可：

```
hive> CREATE TABLE authorize_part (key INT, value STRING)
  > PARTITIONED BY (ds STRING);

hive> ALTER TABLE authorization_part
  > SET TBLPROPERTIES ("PARTITION_LEVEL_PRIVILEGE"="TRUE");
Authorization failed:No privilege 'Alter' found for inputs
{database:default, table:authorization_part}.
Use show grant to get more details.

hive> GRANT ALTER ON table authorization_part to user edward;

hive> ALTER TABLE authorization_part
  > SET TBLPROPERTIES ("PARTITION_LEVEL_PRIVILEGE"="TRUE");

hive> GRANT SELECT ON TABLE authorization_part TO USER edward;

hive> ALTER TABLE authorization_part ADD PARTITION (ds='3');

hive> ALTER TABLE authorization_part ADD PARTITION (ds='4');

hive> SELECT * FROM authorization_part WHERE ds='3';

hive> REVOKE SELECT ON TABLE authorization_part partition (ds='3') FROM USER
edward;

hive> SELECT * FROM authorization_part WHERE ds='3';
Authorization failed:No privilege 'Select' found for inputs
{ database:default, table:authorization_part, partitionName:ds=3, columnName:key}.
Use show grant to get more details.

hive> SELECT * FROM authorization_part WHERE ds='4';
OK
Time taken: 0.146 seconds
```

18.5 自动授权

用户经常会期望创建表后不再执行烦人的授权命令，就可以具有相关的权限，而直接去执行后续的查询，等等。早期，用户可能需要具有ALL权限才可以，不过现在可以为默认情况指定更细节的权限。

属性hive.security.authorization.createtable.owner.grants中可以定义为创建表的用户自动授予对这张表的指定的权限。在下面的这个例子中，并不是授予ALL权限，而是为用户自动授予对其所创建的表的SELECT和DROP权限：

```
<property>
  <name>hive.security.authorization.createtable.owner.grants</name>
  <value>select,drop</value>
</property>
```

类似地，可以在创建表时自动授予指定用户指定的权限。属性hive.security.authorization.createtable.user.grants就控制着这个行为。下面这个例子展示了Hive管理员账号admin1和用户edward默认授予所有表的读权限，而user1只有创建表的权限。

```
<property>
  <name>hive.security.authorization.createtable.user.grants</name>
  <value>admin1,edward:select;user1:create</value>
</property>
```

对于组(group)和角色 (role) 同样具有类似的属性来控制自动授予的权限。对于组，该属性名为hive.security.authorization.createtable.group.grants；对于角色，这个属性是hive.security.authorization.createtable.role.grants。这些属性的值的形式和前面介绍的是相同的。

[1]请参考如下链接：<https://issues.apache.org/jira/browse/HIVE-1264>。

[2]请参考<https://issues.apache.org/jira/browse/HIVE-78>，“Hive”中的权限管理架构”以及如下链接中对于这个功能的描述：

<https://cwiki.apache.org/Hive/languagemanual-auth.html>。

第19章 锁

尽管HiveQL是一种SQL方言，但是Hive缺少通常在update和insert类型的查询中使用到的对于列、行或者查询级别的锁支持。Hadoop中的文件通常是一次写入的（尽管Hadoop确实支持有限的文件追加功能）。因为这个一次写入的天性和MapReduce的streaming类型，访问细粒度锁是不必要的。

不过，既然Hadoop和Hive是多用户系统，那么在一些情况下，锁和协调会是非常有用的。例如，如果一个用户期望锁定一个表，因为使用INSERT OVERWRITE这样的查询就可以修改表的内容，而同时第2个用户也尝试使用这个表解决某个查询问题，这样的查询可能会失败或者产生无效的结果。

Hive可以被认为是一个胖客户端，因为在某种意义上每个Hive CLI、Thrift server或者Web接口实例都不是完全独立于其他实例的。因为这个独立性，所有锁必须由单独的系统进行协调。

19.1 Hive结合Zookeeper支持锁功能

Hive中包含了一个使用Apache Zookeeper进行锁定的锁功能。Zookeeper实现了高度可靠的分布式协调功能。处理需要增加一些额外的设置和配置步骤。Zookeeper对于Hive用户来说是透明的。

设置Zookeeper，需要为其指定一个或者多个服务器来执行它的服务进程。典型的最小配置需要具有3个Zookeeper节点，这样就可以提供一个群体，并保持足够的冗余。

在下一个示例中，我们将使用3个节点：zk1.site.pvt、zk2.site.pvt和zk3.site.pvt。

下载并解压缩一个Zookeeper发行包。通过如下一系列命令，我们就可以将Zookeeper安装到/opt目录下，安装过程需要sudo访问权限

（对于Zookeeper之后的更新的版本，如果有如下命令的话，差不多也是可以通过如下方式安装的）：

```
$ cd /opt
$ sudo curl -o http://www.ecoficial.com/am/zookeeper/stable/zookeeper-3.3.3.tar.gz
$ sudo tar -xf zookeeper-3.3.3.tar.gz
$ sudo ln -s zookeeper-3.3.3 zookeeper
```

创建一个目录用来存放Zookeeper的数据:

```
$ sudo mkdir /var/zookeeper
```

创建一个Zookeeper配置文件 /opt/zookeeper/conf/zoo.cfg。这个配置文件中的内容可以参考下面的信息，当然需要根据用户的安装情况适当进行修改:

```
tickTime=2000
dataDir=/var/zookeeper
clientPort=2181
initLimit=5
syncLimit=2
server.1=zk1.site.pvt:2888:3888
server.2=zk2.site.pvt:2888:3888
server.3=zk3.site.pvt:2888:3888
```

在每台服务器上，都需要创建一个myid文件，并确保文件内容和配置文件中配置的ID匹配。例如，对于zk1.site.pvt这个节点服务器上的myid文件，用户可以通过如下命令进行创建:

```
$ sudo echo 1 > /var/zookeeper/myid
```

最后，通过如下命令启动Zookeeper:

```
$ sudo /opt/zookeeper/bin/zkServer.sh start
```



提示

用户需要使用root用户来启动这个进程，虽然对于大多的进程都无需使用root用户启动。用户可以以通常的标准技术使用其他的用户来执行这个文件。

一旦Zookeeper节点间相互通信，可能就会在一台Zookeeper节点上创建数据，而从另一个节点上读取数据。例如，在某个节点上执行

如下这个会话：

```
$ /opt/zookeeper/bin/zkCli.sh -server zk1.site.pvt:2181
[zk: zk1.site.pvt:2181(CONNECTED) 3] ls /
[zookeeper]
[zk: zk1.site.pvt:2181(CONNECTED) 4] create /zk_test my_data
Created /zk_test
```

然后，从其他某个节点上执行这个会话，或者在之前的那个节点上重新开一个控制台来执行这个会话：

```
$ /opt/zookeeper/bin/zkCli.sh -server zk1.site.pvt:2181
[zk: zk1.site.pvt:2181(CONNECTED) 0] ls /
[zookeeper, zk_test]
[zk: zk1.site.pvt:2181(CONNECTED) 1]
```

唷！好吧，最艰难的部分已经过去了。现在我们需要配置Hive，让其可以使用这些Zookeeper节点来启用并发支持。

在\$HIVE_HOME/hive-site.xml这个配置文件中，需要增加如下属性配置：

```
<property>
  <name>hive.zookeeper.quorum</name>
  <value>zk1.site.pvt,zk1.site.pvt,zk1.site.pvt</value>
  <description>The list of zookeeper servers to talk to.
  This is only needed for read/write locks.</description>
</property>

<property>
  <name>hive.support.concurrency</name>
  <value>true</value>
  <description>Whether Hive supports concurrency or not.
  A Zookeeper instance must be up and running for the default
  Hive lock manager to support read-write locks.</description>
</property>
```

配置好这些属性后，Hive会对特定的查询自动启动获取锁，用户可以通过SHOW LOCKS命令查看当前的所有锁：

```
hive> SHOW LOCKS;
default@people_20111230 SHARED
default@places SHARED
default@places@hit_date=20111230 SHARED
...
```

假设这里的places是分区表，如下这些更加集中的查询也是支持的，其中的省略号可以换成一个适当的分区描述。

```
hive> SHOW LOCKS places EXTENDED;
default@places SHARED
...
hive> SHOW LOCKS places PARTITION (...);
default@places SHARED
...
hive> SHOW LOCKS places PARTITION (...) EXTENDED;
default@places SHARED
...
```

Hive中提供了2种类型的锁，开启并发功能后，它们也就自动被启用了。某个表被读取的时候需要使用共享锁。多重并发共享锁也是允许使用的。

对于其他那些会以某种方式修改表的操作都是需要使用独占锁的。其不仅会冻结其他表修改操作，同时也会阻止其他进程进行查询。

当表是分区表时，对一个分区获取独占锁时会导致需要对表本身获取共享锁来防止发生不相容的变更，例如当表的一个分区正在被修改的时候尝试删除这个表。当然，对表使用独占锁会全局影响所有的分区。

19.2 显式锁和独占锁

用户同样可以显式地管理锁。例如，假设某个Hive会话对表people创建了一个显式锁：

```
hive> LOCK TABLE people EXCLUSIVE;
```

下面是另一个Hive会话，其尝试查询这个被锁定的表：

```
hive> SELECT COUNT(*) FROM people;
conflicting lock present for default@people mode SHARED
FAILED: Error in acquiring locks: locks on the underlying objects
cannot be acquired. retry after some time
```

通过UNLOCK TABLE语句可以对表进行解锁，解锁后其他会话的查询就可以正常工作了：

```
hive> UNLOCK TABLE people;
```

第20章 Hive和Oozie整合

Apache Oozie是一个工作流引擎服务器，其用于运行Hadoop Map/Reduce和Pig任务工作流，官网地址是：<http://incubator.apache.org/oozie/>。Hive本身也具有一个内置的工作流系统。Hive可以将一个查询转化成一个或者多个执行过程，例如map/reduce执行过程或者一个move转移文件的执行过程。如果其中某个过程失败了，Hive就会清理这个进程并报告错误信息。如果其中某个执行过程成功了，Hive就会执行下一个子过程直到整个job执行成功。同时，可以在一个HQL文件中放置多个语句，然后Hive会按照次序执行这些查询，直到文件中所有的语句都执行成功为止。

Hive中的工作流控制系统对于处理单个任务或者处理按照次序执行的多个任务的效果是非常好的。不过，一些工作流要比之复杂得多。例如，用户可能需要这样一个处理过程，其第1步是一个传统的MapReduce任务，而第2步需要使用到第1步的输出作为输入，然后使用Hive进行处理，而最后1步是使用distcp命令将第2步的输出结果传递到一个远程集群中。这些形式的工作流对于Oozie工作流来说都是可以进行处理的。

Oozie工作流任务是一系列“动作”的有向无环图（DAG）。一些工作流是根据需要进行触发的，但大多数情况下，我们有必要基于一定的时间段和（或）数据可用性和（或）外部事件来运行它们。Oozie协调系统让用户可以基于这些参数来定义工作流执行计划。Oozie一个重要的特点就是工作流的状态是和发起任务的客户端分离开来的。这种分离式的（发起，然后不再管理）任务启动方式是非常有用的。通常一个Hive任务是和提交这个任务的控制台联系在一起的。如果控制台中断了，那么其任务也就完成了一半了。

20.1 Oozie提供的多种动作（Action）

Oozie提供了多个内置的动作。如下列举了其中的一些，并进行了简要的描述。

1. MapReduce

用户提供Mapper类和Reducer类，并设置一些附属变量。

2. Shell

包含参数的Shell命令也可作为动作来执行。

3. Java 动作

含有main方面的Java类，可以指定参数后执行。

4. Pig

可以执行Pig脚本。

5. Hive

可以执行Hive的HQL查询。

6. DistCp

可以执行DistCp命令，将数据拷贝到另一个HDFS集群，或从另一个HDFS集群拷贝数据到当前集群。

Hive Thrift Service Action

Hive内置的动作可以很好地工作，但是其有一些缺点。它们会将Hive作为胖客户端来使用。Hive分支中的大部分，包括JAR文件和配置文件，都需要拷贝到工作流目录下。当Oozie启动一个动作时，其就会随机地选择一个TaskTracker节点进行启动。如果用户设置元数据存储只能从指定的主机进行连接的话，那么就可能存在连接元数据存储的问题。因为如果任务失败了，Hive会遗留下如*hive-history*或一些放在/tmp目录下的东西，所以需要确保清理所有TaskTracker上面的这些信息。

通过使用Hive Thrift Service（参见第16章内容），（基本）可以解决胖客户端问题。其中HiveServiceBAction（表示“Hive服务B计划行动方案”）使得可以通过Hive Thrift Service提交任务（job）。这样有一个好处，即可以将所有的Hive操作汇集到一个预先定义的执行Hive服务的节点集合上。

```
$ cd ~
$ git clone git://github.com/edwardcapriolo/hive_test.git
$ cd hive_test
$ mvn wagon:download-single
$ mvn exec:exec
$ mvn install

$ cd ~
$ git clone git://github.com/edwardcapriolo/m6d_oozie.git
$ mvn install
```

20.2 一个只包含两个查询过程的工作流示例

通过配置特定的目录结构可以创建一个工作流。这里的目录结构里含有我们所需要的JAR文件，一个是*job.properties*文件，另一个是*workflow.xml*文件。这个目录必须创建在HDFS中，但最好先在本地创建好文件夹，然后将其拷贝到HDFS中：

```
$ mkdir myapp
$ mkdir myapp/lib
$ cp $HIVE_HOME/lib/*.jar myapp/lib/
$ cp m6d_oozie-1.0.0.jar myapp/lib/
$ cp hive_test-4.0.0.jar myapp/lib/
```

文件*job.properties*中配置有文件系统*NameNode*地址和*Jobtracker*地址。同时，还可以在这里设置一些Hadoop Job配置文件中的属性信息：

如下是个*job.properties*文件内容的例子：

```
nameNode=hdfs://rs01.hadoop.pvt:34310
jobTracker=rjt.hadoop.pvt:34311
queueName=default
oozie.libpath=/user/root/oozie/test/lib
oozie.wf.application.path=${nameNode}/user/root/oozie/test/main
```

文件*workflow.xml*对动作进行了定义：

```
<workflow-app xmlns="uri:oozie:workflow:0.2" name="java-main-wf">
  <start to="create-node"/>
  <!--The create-node actual defines a table if it does not
already exist-->
  <action name="create-node">
    <java>
      <job-tracker>${jobTracker}</job-tracker>
      <name-node>${nameNode}</name-node>
      <configuration>
        <property>
          <name>mapred.job.queue.name</name>
```

```

        <value>${queueName}</value>
    </property>
</configuration>
<main-class>com.m6d.oozie.HiveServiceBAction</main-class>
<arg>rhiveservice.hadoop.pvt</arg>
<arg>10000</arg>
<arg>CREATE TABLE IF NOT EXISTS zz_zz_abc (a int, b int)</arg>
</java>
<!-- on success proceeded to query_node action -->
<ok to="query_node"/>
<!-- on fail end the job unsuccessfully-->
<error to="fail"/>
</action>

<!-- populate the contents of the table with an
insert overwrite query -->
<action name="query_node">
<java>
    <job-tracker>${jobTracker}</job-tracker>
    <name-node>${nameNode}</name-node>
    <configuration>
        <property>
            <name>mapred.job.queue.name</name>
            <value>${queueName}</value>
        </property>
    </configuration>
    <main-class>com.m6d.oozie.HiveServiceBAction</main-class>
    <arg>rhiveservice.hadoop.pvt</arg>
    <arg>10000</arg>
    <arg>INSERT OVERWRITE TABLE zz_zz_abc SELECT dma_code,site_id
FROM BCO WHERE dt=20120426 AND offer=4159 LIMIT 10</arg>
</java>
    <ok to="end"/>
    <error to="fail"/>
</action>

<kill name="fail">
    <message>Java failed, error message
    [${wf:errorMessage(wf:lastErrorNode())}]</message>
</kill>
<end name="end"/>
</workflow-app>

```

20.3 Oozie 网页控制台

使用Oozie网页控制台可以获得操作执行的细节，也因此便于进行任务错误定位。Oozie会在每个map任务（task）中启动每个动作并获取其所有的输入和输出。Oozie可以很好地展示这些信息并提供链接，方便到Hadoop的JobTracker网页控制台查看这些任务（job）状态信息。

图20-1是一张Oozie网页控制台的屏幕截图。




图20-1 Oozie网页控制台屏幕截图

20.4 工作流中的变量

基于完全静态查询的工作流是很有用的，但是并不太实用。Oozie中的大多数使用场景是执行今天或本周的一系列文件的处理过程。

在前面的工作流中，你可能注意到了KILL这个标记以及其中插入的变量：

```
<kill name="fail">
  <message>Java failed, error message
    [${wf:errorMessage(wf:lastErrorNode())}]</message>
</kill>
```

Oozie提供了一个ETL来访问这些变量。*job.properties*文件中定义的键-值对可以通过这种方式进行引用。

20.5 获取输出

Oozie中还提供了一个可以放置到动作中的<captureOutput/>标记。通过这个标记可以捕获输出，并可以将其连同错误信息通过邮件发出或者将输出发送给其他处理过程。Oozie在每个动作中都设置了一个Java属性，它可用于输出那些可以写入的文件名。如下代码展示了如何获取这个属性：

```
private static final String  
OOZIE_ACTION_OUTPUT_PROPERTIES = "oozie.action.output.properties";  
  
public static void main(String args[]) throws Exception {  
    String oozieProp = System.getProperty(OOZIE_ACTION_OUTPUT_PROPERTIES);  
}
```

用户的应用程序可以向该位置输出数据。

20.6 获取输出到变量

我们已经讨论了如何获取输出以及如何获取Oozie变量，将这两者结合在一起使用，就可以满足日常的工作流使用需求了。

看一下我们前面的那个例子，可以看到，我们是从硬编码的FROM BCO WHERE dt=20120426这天获取数据的。如果我们期望每天都执行这个工作流的话，那么我们就需要将硬编码的dt=20120426内容使用一个日期变量进行替换：

```
<action name="create_table">  
    <java>  
        <job-tracker>${jobTracker}</job-tracker>  
        <name-node>${nameNode}</name-node>  
        <configuration>  
            <property>  
                <name>mapred.job.queue.name</name>  
                <value>${queueName}</value>  
            </property>  
        </configuration>  
        <main-class>test.RunShellProp</main-class>  
        <arg>/bin/date</arg>  
        <arg>+x=%Y%m%d</arg>  
        <capture-output />  
    </java>  
    <ok to="run_query"/>  
    <error to="fail"/>  
</action>
```

这将产生如下类似的输出：

```
$ date +x=%Y%m%d
x=20120522
```

那么就可以在这个处理过程后面使用这个输出了：

```
<arg>You said ${wf:actionData('create_table')['x']}
```

使用Oozie还可以做很多其他的工作，包括将Hive任务（job）和使用其他工具（如Pig、Java MapReduce等）实现的任务（job）的整合使用。

第21章 Hive和亚马逊网络服务系统 (AWS)

——*Mark Grover*

Amazon提供的作为AmazonWeb服务 (AWS) 一部分的就是弹性MapReduce (EMR)。使用EMR可以按需组建一个由节点组成的集群。这些集群用于Hadoop和Hive的安装和配置。(用户也可以配置这个集群, 以使用Pig或者其他工具。) 用户可以执行Hive查询语句, 然后在完成所有任务后终止这个集群, 整个过程只需为使用这个集群的时间付费。本节将描述如何使用弹性MapReduce, 介绍一些基本的实践, 包括使用EMR和其他一些替代方案的属性和配置。

在阅读本章时, 用户可以通过如下链接获取在线AWS文档说明: <http://aws.amazon.com/elasticmapreduce/>。本章将不会涵括所有的在Amazon EMR中使用Hive的细节。本章只会提供一个概述并详细探讨一些实践操作。

21.1 为什么要弹性MapReduce

较小的团队和初创的公司经常没有足够的资源来建立自己的集群, 而自建的集群需要在初始阶段进行固定的投资消耗, 需要有能力搭建、服务和切换, 包括维护Hadoop和Hive安装。

从另一方面来说, 弹性MapReduce性价比高, 而且其由Amazon来安装和维护。这对于那些没有能力或者不期望投资自己的集群的团队来说是非常有益的, 甚至对于大的团队也可以在不影响自己的生产集群的情况下对新工具和新创意进行测试。

21.2 实例

一个Amazon集群由一个或者多个实例组成。各种实例大小不同, 使用不同的RAM, 提供不同的计算能力、存储空间、平台和I/O处理

能力。很难说针对用户的使用场景使用多少的集群可以达到最佳效果。使用EMR，可以在开始的时候使用较小的实例，并使用如Ganglia这样的工具监控性能，然后对多个不同大小的实例进行试验，找到平衡成本和性能的最佳值。

21.3 开始前的注意事项

在使用Amazon EMR之前，用户需要先设置一个Amazon Web Services(AWS)账号。在“*Amazon EMR*”开始指南中提供了如何注册一个AWS账号的操作说明。

用户还需要创建一个Amazon S3数据桶用于存储用户输入数据并获取用户Hive处理过程的输出结果。

当用户设置好AWS账号后，需要确保其所有的Amazon EC2实例、键对、安全组和EMR 工作流都位于同一个区域以避免跨区域数据传输消耗。将Amazon S3数据桶和EMR 工作流设置在同一个区域将获得更高的性能。

尽管Amazon EMR支持多个版本的Hadoop和Hive，不过只有一些配套的Hadoop和Hive版本才支持Amazon EMR。查看Amazon EMR文档以获取支持的Hadoop和Hive组合版本。

21.4 管理自有EMR Hive集群

Amazon提供了多种方式来创建、终止和修改Hive 集群。目前用户可以通过如下3种方式来管理用户的EMR Hive集群。

1. EMR AWS管理控制台（基于Web的前端控制台）

这是搭建集群而无需安装过程的最简单的方式。不过，当规模增大时，最好使用其他的方式进行搭建。

2. EMR命令行交互界面

这种方式允许用户使用简单的基于Ruby的名为elastic-mapreduce的CLI来管理集群。

Amazon EMR在线文档描述了如何安装和使用CLI。

3. EMR API

这种方式允许用户使用一个名为EMR API的特定语言的SDK来管理EMR集群。在Amazon EMR文档中有介绍下载和使用这种SDK的详细介绍。SDK目前支持Android、iOS、Java、PHP、Python、Ruby、Windows和.NET。SDK的一个缺点是，有时特定的SDK包含的实现可能没有最新版本的AWS API提供的新。

通常会使用多种方式来管理Hive集群。

下面是一个使用Ruby elastic-mapreduce CLI来创建一个包含有配置好的Hive的单节点Amazon EMR集群的例子。其不仅提供了执行任务和退出的功能，还为集群安装了一个交互界面。这样的集群是学习Hive的理想工具。

```
elastic-mapreduce --create --alive --name "Test Hive" --hive-interactive
```

如果用户想使用Pig的话，那么在这里增加--pig-interface选项即可。

下一步就是按照Amazon EMR文档中描述的方式登录到这个集群中了。

21.5 EMR Hive上的Thrift Server服务

通常情况下，Hive Thrift Server（请参考第16章的内容）是监听来自端口10 000的连接的。不过，在Amazon Hive安装中，这个端口值取决于所使用的Hive的版本。这样做的目的是可以允许用户安装并开发支持多个版本的Hive。因此，Hive 0.5.x版本使用的是10 000端口。Hive 0.7.x使用的是10 001端口，而Hive v0.7.1使用的是10 002端口。当Amazon EMR中新增新版本的Hive时这个端口值应该是要改变的。

21.6 EMR上的实例组

每个Amazon 集群都具有一个或者多个节点。每个节点都可以放入到如下3种实例组中的一组中。

1. 管理者实例组

这个实例组只含有一个节点，称之为管理者节点。这个管理者节点和Hadoop的master节点的功能是相同的。其上面运行着namenode和jobtracker守护进程，不过这上面还安装有Hive。另外，其上还安装有一个MySQL服务器，其被配置为EMR Hive的元数据存储。（Apache Hive中默认是使用Derby作为元数据存储的，这里不会使用这个。）在管理者节点上还运行着一个实例管理器。其用于在其他2种实例组中执行和管理其他实例。需要注意的是这个实例管理器同样会使用到管理者节点上的MySQL服务器。如果这个MySQL服务器不可用的话，那么这个实例控制器就无法执行和管理实例。

2. 核心实例组

核心实例组中的节点和Hadoop slave节点的具有相同的功能，会同时启动datanode和tasktracker守护进程。这些节点用于MapReduce任务计算，同时也用于HDFS存储。一旦集群启动，这个实例组内的节点个数只能增不能减。需要注意的是，一旦集群终止了，这些节点上存储的数据就会丢失。

3. 任务（task）实例组

这是一个可选的实例组。在本组中的节点同样具有Hadoop中salve节点的功能。不过，它们只执行tasktracker进程。因此，这些节点用于MapReduce任务（task），但无法用于存储HDFS数据块。集群启动后，任务（task）实例组内的节点个数可能有时增加，有时减少。

当用户在高峰期的那几个小时增加集群处理能力，然后再调整到正常情况时，使用任务（task）实例组是非常便利的。同样对于那些既希望可以低成本使用现买现卖实例，而又期望当集群中节点被移除后不会有丢失数据的风险的情况，同样是适用这种解决办法的。

如果用户使用的是单点集群的话，那么这个节点将同时是管理者节点和核心节点。

21.7 配置EMR集群

在使用EMR集群时，用户经常需要部署自己的配置文件。一般要配置的文件有hive-site.xml、.hiverc、hadoop-env.sh。Amazon提供了一种方式来重载这些配置文件。

21.7.1 部署hive-site.xml文件

为了重载hive-site.xml文件，首先需要上传用户自定义hive-site.xml文件到S3中。我们假设其已经上传到S3中如下路径：
s3n://example.hive.oreilly.com/tables/hive_site.xml。



提示

建议使用最新s3n“模式”来访问S3，其比之前的s3模式具有更高的性能。

如果用户是通过elastic-mapreduce Ruby客户端来启动集群的话，那么可以使用类似如下的命令使用用户自定义的hive-site.xml来分割集群：

```
elastic-mapreduce --create --alive --name "Test Hive" --hive-interactive \
--hive-site=s3n://example.hive.oreilly.com/conf/hive_site.xml
```

如果用户是使用SDK来分割集群的话，那么可以使用合适的方法来重载hive-site.xml文件。在引导程序之后，用户需要2个配置步骤。其一是安装Hive，其二是部署hive-site.xml文件。第1个步骤安装Hive需要同时调用--install-hive和--hive-versions，后者的值是使用逗号分割符的期望安装到集群中的Hive版本列表。

第2个步骤是安装Hive site配置文件，使用的命令是--install-hive-site，其后跟着一个参数如--hive-site=s3n://example.hive.oreilly.com/tables/hive_site.xml，来指定要使用的hive-site.xml文件所在的位置。

21.7.2 部署.hiverc脚本

对于.hiverc，用户同样需要先将其上传到S3中。然后用户可以使用配置过程或者在引导程序来将这个文件部署到集群中。需要注意的是.hiverc可以部署到用户根目录下，或者部署在Hive安装目录下的bin目录下。

1. 使用配置步骤部署.hiverc脚本

在写本篇时，Amazon提供的名为hive-script的Ruby脚本还没有提供重载.hiverc文件的功能，这个脚本可以在如下地址查看到：s3n://us-east-1.elasticmapreduce/libs/hive/hive-script。

因此，无法像安装hive-site.xml文件那么轻松地安装.hiverc文件。不过，如果用户不介意修改Ruby代码的话，通过简单修改Amazon提供的hive-script脚本是可以启用安装.hiverc的。进行这样的修改之后，需要将这个文件上传到S3，然后使用这个版本而非Amazon提供的版本即可。修改脚本后可以将.hiverc安装到用户的根目录下或者Hive安装目录下的bin目录下。

2. 使用辅助工具脚本部署.hiverc脚本

或者，用户可以创建一个自定义的引导程序脚本来将.hiverc文件传送到管理者节点的用户根目录下或Hive的安装目录下的bin目录下。在这样的脚本中，用户应该首先使用S3访问码配置集群上的s3cmd脚本，用户也需要使用这个S3访问码才能从S3下载.hiverc文件。然后，使用类似如下这样的简单命令来从S3中下载文件，并将其部署到用户根目录下：

```
s3cmd get s3n://example.hive.oreilly.com/conf/.hiverc ~/.hiverc
```

然后在集群创建过程中使用一个引导程序动作来调用这个脚本，这和设置其他的引导程序动作是一样的。

21.7.3 建立一个内存密集型配置

如果用户执行的是一个内存密集型的任务（Job），Amazon提供了一些预定义的引导程序动作可用于调优Hadoop配置参数。例如，在划分集群的时候可以使用memory-intensive引导程序动作，可以在

elastic-mapreduce –create 命令后使用如下的标记（为显示美观，进行了换行）：

```
--bootstrap-action
s3n://elasticmapreduce/bootstrap-actions/configurations/latest/memory-intensive
```

21.8 EMR上的持久层和元数据存储

EMR集群本身开始时就会在集群的管理者节点上安装一个MySQL服务器。默认情况下，EMR Hive使用这个MySQL服务器作为元数据存储。不过，当这个集群被用户终止后所有存在节点上的数据也将会被清空！这通常是不可接受的。因为用户需要将表模式等信息保持在一个稳固的元数据存储上。

用户选取使用如下多种方法中的一种来绕过这个限制。

1. 使用EMR集群外的稳固的元数据存储

在第2.5.3节“使用JDBC连接元数据存储”中我们已经介绍过了如何在Hive中安装使用外部元数据存储。用户可以选用基于MySQL的Amazon RDS（关系型数据服务），或者其他内部数据库服务器来作为元数据存储。当用户期望多个EMR集群使用同一个元数据存储或者同一个EMR集群上执行多个版本的Hive时，这是可以采取的最好的选择。

2. 使用初始化脚本

如果用户不期望使用外部数据库服务器来作为元数据存储的话，那么用户同样可以结合用户初始化脚本来使用管理者节点上的元数据存储。用户可以将类似如下的创建表语句保存在名为startup.q的文件中：

```
CREATE EXTERNAL TABLE IF NOT EXISTS emr_table(id INT, value STRING)
PARTITIONED BY (dt STRING)
LOCATION 's3n://example.hive.oreilly.com/tables/emr_table';
```

很有必要在创建表语句中使用IF NOT EXISTS语句，来确保不会删除管理者节点元数据存储中由之前初始化脚本创建好的同名的表。

到这里，我们已经在元数据存储中创建好表结构信息了，但是我们还没有加入分区信息。在startup.q文件中创建表语句后加入如下一行命令即可：

```
ALTER TABLE emr_table RECOVER PARTITIONS;
```

这行命令可以在元数据存储中补全所有的分区元数据信息内容。除了使用用户自定义的初始化脚本外，还可以使用.hiverc达到同样的效果，这个文件在Hive CLI启动时会自动执行一遍。（我们将在第21.14节“EMR和EC2以及Apache Hive的比较”中进行讨论。）

使用.hiverc的好处是其可以被自动调用。而缺点是，每次执行，Hive CLI都会被调用一次，这就为后续的调用带来了不必要的时间消耗。

使用用户自定义初始化脚本的好处是，用户可以在工作流的执行周期中进行更有效的控制。不过，用户需要自己控制这个调用。无论如何，使用一个保存Hive语句的文件来用于初始化有一个附带的好处是，用户可以通过版本控制来跟踪DDL变更情况。



提示

当表和分区变得很多时，元数据信息将变得更多，这样这个系统中的初始化脚本执行的时间就会越来越长。因此如果表或分区非常多，不建议使用这种方法。

3. 在S3上进行MySQL dump操作

还有一种方式（尽管麻烦），就是在集群终止之前对元数据存储进行备份，然后在下一个工作流开始时恢复到元数据存储中。S3在集群未使用时执行这个备份是最合适不过了。

需要注意的是，这个元数据存储并不能在EMR集群上支持的多个版本Hive共用。假设用户划分出一个集群，其中安装有Hive 0.5.0和v0.7.1 2个版本的话。当用户使用Hive v0.5创建了一张表后，那么是无

法使用Hive v0.7.1来访问这张表的。如果用户期望多个Hive版本共用同一个元数据存储，用户必需要使用一个外部稳固的元数据存储。

21.9 EMR集群上的HDFS和S3

在EMR集群中HDFS和S3都有其独特的角色。当集群终止后其上所有的数据都会被清除掉。因为HDFS是由核心实例组中的临时存储节点组成的，所以当集群终止后HDFS上存储的数据会全部丢失。

从另一方面来说，S3提供了一个和EMR集群相关联的持久性存储。不过，集群中的输入数据必须是存储在S3上的数据，而Hive处理过程产生的最终结果同时也必须持久化到S3中。不管怎样，S3是HDFS的一个昂贵的替代存储方案。不过，处理过程中的中间数据应该存储在HDFS中，而只有需要持久化的最终结果才存储到S3中。

需要注意的一点是，如果使用S3作为输入数据源的话，存在一个缺点就是，无法使用Hadoop的本地化数据处理优化，其带来的性能表现可能是非常显著的。如果对于用户的分析来说这个功能是非常必要的，那么建议最好在处理前从S3中将这些“热”数据导入到HDFS中，然后再进行处理。通过这个初始过程，就可以在后续的处理中使用Hadoop的本地处理优化。

21.10 在S3上部署资源、配置和辅助程序脚本

用户需要将所有的初始化脚本、配置脚本（例如hive-site.xml和.hiverc文件）、资源文件（例如需要载入到分布式缓存中的文件、UDF或者streaming使用到的JAR文件等）等上传到S3中。因为EMR Hive和Hadoop安装原生地就可以处理S3路径，所以在随后的Hadoop处理任务中可以直接使用这些文件。

例如，用户可以将如下几行命令增加到.hiverc文件中，其可以正常执行：

```
ADD FILE s3n://example.hive.oreilly.com/files/my_file.txt;
ADD JAR s3n://example.hive.oreilly.com/jars/udfs.jar;
CREATE TEMPORARY FUNCTION my_count AS 'com.oreilly.hive.example.MyCount';
```

21.11 S3上的日志

Amazon EMR会将日志写入到log-uri字段所指向的S3路径下。其中包含有集群引导程序动作所产生的日志和在不同的集群节点上执行的守护进程所产生的日志。log-uri这个配置项可以在elastic-mapreduce Ruby客户端安装目录下的*credentials.json*文件中进行配置；或者也可以在使用elastic-mapreduce划分集群时，使用--log-uri标记显式地进行指定。如果这个内容没有设置的话，那么就无法在S3中获得那些日志。

如果用户设置的工作流一旦认为遇到错误就终止掉的话，那么在集群终止后会丢失所有存放在集群上的日志信息。如果用户指定了log-uri配置的值，那么即使集群终止掉了，还是可以在S3上指定的路径下找到这些日志的。这些日志可以帮助用户确认产生失败的原因，帮助解决问题。

不过，如果用户将日志保存在S3中要记住尽量频繁地将不需要的日志清除掉以减少产生不必要的存储成本！

21.12 现买现卖

现买现卖业务允许用户随着需求的变化获得更低的价格来使用Amazon实例。Amazon的在线文档对其有着非常详细的描述。

假设根据实际使用情况，用户希望所具有的3个实例组是现买现卖的。在这种情况下，在工作流的任意一个阶段都是可能导致集群终止的，这样就会导致丢失中间临时数据。如果重新进行这个计算很“便宜”的话，那么这可能并非是个严重的问题。一种解决办法就是将中间数据持久化到S3中，那么任务就可以从这些镜像中重新执行了。

另一种方式就是只将任务实例组的节点作为现买现卖节点。如果这些现买现卖节点因为无效或者因为现买现卖价格增长而剔除出集群的话，原来的工作流在管理者和核心节点上还可以继续执行，而且不会有数据丢失。现买现卖节点重新加入到集群中后，MapReduce任务可以侦测到它们，可以加快整个工作流。

使用elastic-mapreduce Ruby客户端，现买现卖实例可以通过--bid-price选项指定一个权重来进行排序。下面这个例子展示了如何创建一

个具有单个管理者、2个核心节点和2个现买现卖节点（位于任务实例组）的集群，并为其指定权重为10美分：

```
elastic-mapreduce --create --alive --hive-interactive \
--name "Test Spot Instances" \
--instance-group master --instance-type m1.large \
--instance-count 1 --instance-group core \
--instance-type m1.small --instance-count 2 --instance-group task \
--instance-type m1.small --instance-count 2 --bid-price 0.10
```

如果用户使用Java SDK划分一个微集群的话，那么可以使用下面的GroupConfig实例配置管理者、核心和任务实例组：

```
InstanceGroupConfig masterConfig = new InstanceGroupConfig()
.withInstanceCount(1)
.withInstanceRole("MASTER")
.withInstanceType("m1.large");
InstanceGroupConfig coreConfig = new InstanceGroupConfig()
.withInstanceCount(2)
.withInstanceRole("CORE")
.withInstanceType("m1.small");
InstanceGroupConfig taskConfig = new InstanceGroupConfig()
.withInstanceCount(2)
.withInstanceRole("TASK")
.withInstanceType("m1.small")
.withMarket("SPOT")
.withBidPrice("0.05");
```



提示

如果某个map或者reduce任务（task）失败了，Hadoop就需要重新启动它们。如果同一个task失败了4次（可配置的，可以通过设置MapReduce属性mapred.map.max.attempts修改map任务的最多尝试次数；通过修改mapred.reduce.max.attempts可以修改reduce任务的最多尝试次数），那么整个任务（job）就会失败。如果依赖于太多的现买现卖实例的话，那么用户的任务（job）可能会因为TaskTracker被移除出集群导致无法推测执行或导致整个任务（job）失败。

21.13 安全组

Hadoop的*JobTracker*和*NameNode*用户接口可以在EMRmaster节点上分别在端口9 100和9 101上被访问到。用户可以通过ssh隧道或者使用动态SOCKS代理来访问它们。

为了在用户客户端机器上（在Amazon网络之外）通过浏览器访问到这些信息，用户需要通过AWS网页控制台对Elastic MapReduce管理者安全组进行修改，增加一个新的用户自定义TCP规则将客户端机器的IP在9 100和9 101端口上进行绑定即可。

21.14 EMR和EC2以及Apache Hive的比较

对于EMR的一个弹性的替代方式就是引入多个Amazon EC2节点，并将Hadoop和Hive安装在一个定制的Amazon机器映像（AMI）中。这种方式使用户可以更好地对Hadoop和Hive的版本和配置进行控制。例如，用户可以在EMR发布某个工具最新版本之前尝试使用其新版本。

这种方式的一个缺点是，EMR发布的定制版可能在Apache Hive发行版中并没有包含。例如，目前Apache Hive还无法完全支持S3文件系统（请参考 [JIAR HIVE-2318](#)）。对于Amazon S3查询还存在一个优化，用于减少初始化时间。这个功能只包含在EMR Hive中。通过增加如下配置到hive-site.xml文件中，可以开启此优化：

```
<property>
  <name>hive.optimize.s3.query</name>
  <value>true</value>
  <description> Improves Hive query performance for Amazon S3 queries
  by reducing their start up time </description>
</property>
```

同样地，也可也在Hive CLI中执行如下命令启用此功能：

```
set hive.optimize.s3.query=true;
```

还有一个例子展示的是，如果在HDFS或S3中的目录结构是正确的话，那么可以通过命令自动补全元数据存储中的分区信息。当外部处理程序生成Hive表的分区目录时，使用这种方式补全元数据是非常方便的。通过如下命令即可达到这个效果，其中emr_table是表名：

```
ALTER TABLE emr_table RECOVER PARTITIONS;
```

下面是一个创建表的语句，供参考：

```
CREATE EXTERNAL TABLE emr_table(id INT, value STRING)
PARTITIONED BY (dt STRING)
LOCATION 's3n://example.hive.oreilly.com/tables/emr_table';
```

21.15 包装

Amazon EMR提供了一个弹性的、可扩展的、安装配置简单的方式来搭建一个Hadoop和Hive集群，启动机器就可以执行查询。对于存储在S3上的数据同样是可以操作的。尽管大多数的配置已经为用户设置好了，用户还是有足够的灵活的方式进行一些自定义的配置。

第22章 HCatalog

22.1 介绍

在Hadoop中使用Hive进行数据处理，除了可以提供一种类SQL的语言供使用外，还提供了其他多个不错的功能。Hive可以存储元数据，这意味着用户不需要记住数据的模式（schema）信息，同时，也意味着用户无需关注数据实际存储在哪里，以及以什么样的存储格式进行存储的。这就使得数据生产者、数据消费者和数据管理者之间相分离。数据生产者可以往数据中新增一列，而不会破坏数据消费者们的数据只读应用。数据管理者可以重置数据来修改存储格式，而无需修改数据生产者或者数据消费者的应用。

大部分的资深Hadoop用户不会仅使用一种工具来进行数据生产和数据消费。通常，用户都会以如下工具中的一种来开始使用Hadoop：Hive、Pig、MapReduce或者其他工具。当用户对于Hadoop的使用越来越深入后，他们将会发现他们所选择的工具并非是处理新任务的最优选择。对于刚开始使用Hive进行分析型查询的用户来说，他们可能会发现在进行ETL处理或构建数据模型时使用Pig会更好。而对于从Pig入手的用户来说，他们可能会发现在处理分析型查询的时候使用Hive会更好。

尽管像Pig和MapReduce这样的工具是不需要元数据的，但是如果提供了元数据信息的话也是有好处的。共享同一个元数据库可以使用户在多种工具间更容易地共享数据。使用MapReduce或者Pig加载和归一化数据，然后使用Hive来进行分析，这样的工作流是非常常见的。当所有的工具共享使用同一个元数据存储时，每种工具的用户都可以立即访问到由其他工具产生的数据，而无需其他加载或者转换步骤。

HCatalog的存在就是为了满足这些需要的。其可以使Hive的元数据存储为基于Hadoop的其他工具所共用。其为MapReduce和Pig提供了连接器，这样用户就可以使用那些工具，从Hive数据仓库中读取和写入数据。其还提供了一个命令行工具，便于没有使用Hive的用户通过Hive DDL语句操作元数据存储。其还提供了一个消息通知服务，这样

对于Oozie这样的工作流工具，在数据仓库提供新数据时，可以通知到这些工作流工具。

HCatalog是相对独立于Hive的一个独立的Apache项目。其是Apache孵化器的一部分，大多数的Apache项目都是从这个孵化器中开始的。其有助于为其内部的项目构建社区并学习如何开发Apache开源软件。在写本书时，最新的版本是HCatalog 0.4.0-incubating。

这个版本适用于Hive 0.9、Hadoop 1.0和Pig 0.9.2。

（译者注：HCatalog 目前已经合并到Apache Hive中了，在Apache Hive 0.10.0正式引入了Hcatalog。）

22.2 MapReduce

22.2.1 读数据

MapReduce使用Java类InputFormat来读取输入数据。绝大多数情况下，这些类会直接从HDFS中读取数据。InputFormat的一些实现类同样提供了从HBase、Cassandra和其他数据源读取数据的功能。

InputFormat的任务是双重的。首先，其决定了数据是如何划分成数据片然后为MapReduce的map任务（task）所并行处理的。其次，其提供了一个RecordReader，MapReduce使用这个类来从输入数据源中读取记录，然后将其转换成键和值来供map任务（task）进行处理。

HCatalog提供了一个HCatInputFormat类来供MapReduce用户从Hive的数据仓库中读取数据。其允许用户只读取需要的表分区和字段。同时其还以一种方便的列表格式来展示记录，这样就不需要用户来进行划分了。



提示

HCatInputFormat实现了Hadoop 0.20 API，也就是org.apache.hadoop.mapreduce，而不是Hadoop 0.18的org.apache.hadoop.mapred API。这是因为其需要MapReduce (0.20) API中新增的某些功能。这意味着MapReduce用户需要使用这些接

口来和HCatalog进行交互。不过，Hive所需要的用于从磁盘读取数据的InputFormat也可以是旧的mapred下的接口实现的。因此如果用户当前使用的数据的格式是使用MapReduce InputFormat的话，那么就可以使用HCatalog。InputFormat这个类在新接口mapreduce API中是一个类，而在旧接口mapred API中是一个接口，不过前面都是将其作为类进行引用的。

在初始化HCatInputFormat时，首先要做的事情就是指定要读取的表。通过创建一个InputJobInfo类，然后指定数据库、表和分区过滤条件就可以达到这个目地。

```
/**  
 * Initializes a new InputJobInfo  
 * for reading data from a table.  
 * @param databaseName the db name  
 * @param tableName the table name  
 * @param filter the partition filter  
 */  
public static InputJobInfo create(String databaseName,  
    String tableName,  
    String filter) {  
    ...  
}
```

databaseName表示表所在的Hive数据库（或模式schema）。如果这个值为null，那么就会使用默认的名为default的数据库。tableName表示将要读取的表的表名。它必须是非null的，而且必须是Hive中实际存在的一张表。filter表示用户期望读取哪些分区下的数据。如果这个值为null的话，那么将读取整个表。这些需要特别小心，因为读取一张大表的所有分区将会导致扫描大量的数据。

过滤器的格式类似于类SQL的where语句部分。这里应该只允许指定分区字段。例如，假设要读取的分区表的分区字段名为datestamp，那么过滤器可能就类似于 datestamp = "2012-05-26" 这样的格式。过滤器可以包含有=、>、>=、<、<=、and和or操作符。

对于Hive v0.9.0和之前的版本，在ORM映射层存在一个bug，会导致对于>、>=、<或<=这样的过滤条件执行失败。



提示

可以通过<https://issues.apache.org/jira/browse/HIVE-2084>获取HIVE-2084.D2397.1.patch并将这个patch打到用户当前的Hive版本上，然后重新编译，就可以解决这个问题。这确实会存在一些风险，不过这取决于用户是如何部署Hive的。在这个JIRA下可以看到一些讨论信息。

对于InputJobInfo实例和包含MapReduce任务（job）的Job实例，可通过HCatInputFormat的setInput将其传递给HCatInputFormat。

```
Job job = new Job(conf, "Example");
InputJobInfo inputInfo = InputJobInfo.create(dbName, inputTableName, filter);
HCatInputFormat.setInput(job, inputInfo);
```

map任务（task）需要指定值的类型是HCatRecord的。键的类型并不重要，因为HCatalog并不会将键提供给map任务（task）。例如，一个通过HCatalog读取数据的map任务（task）可能是如下形式的：

```
public static class Map extends
    Mapper<WritableComparable, HCatRecord, Text, Text> {

    @Override
    protected void map(
        WritableComparable key,
        HCatRecord value,
        org.apache.hadoop.mapreduce.Mapper<WritableComparable,
            HCatRecord, Text, HCatRecord>.Context context) {
        ...
    }
}
```

HCatRecord是HCatalog提供的一个用于和记录交互的类。其提供了简单的get和set方法，可以通过位置或者名称来获取记录。如果是通过列名获取字段内容的话，那么就必须提供表的模式（schema）信息，因为每个独立的HCatRecord都不会保存一份这个表模式（schema）的引用信息。可以通过HCatInputFormat.getOutputSchema()方法获取到表模式信息。因为Java不允许按照返回值类型进行方法重载，对于不同的数据类型都需要提供其相应的get和set方法。这些方法使用的是类型对象而非标量类型（也就是说使用java.lang.Integer这样的Java对象，而不是像int这样的标量）。这就允许将null作为一个值来表示。同时还提供了对Java对象的get和set方法实现。

```
// get the first column, as an Object and cast it to a Long
Long cnt = record.get(0);
```

```
// get the column named "cnt" as a Long
Long cnt = record.get("cnt", schema);

// set the column named "user" to the string "fred"
record.setString("user", schema, "fred");
```

通常程序不需要读取一个输入的所有字段内容。在这种情况下，尽早尽快地去除掉不需要的字段很有意义。这对于像RCFile这样的列式存储更是有益的，越早过滤掉不需要的字段就意味着从磁盘读取更少的数据。这可以通过传递一个描述所需字段的模式来完成。这个过程必须在job配置时间内完成。如下这个例子将配置用户的job只读取2个字段，字段名分别是user和url：

```
HCatSchema baseSchema = HCatBaseInputFormat.getOutputSchema(context);
List<HCatFieldSchema> fields = new List<HCatFieldSchema>(2);
fields.add(baseSchema.get("user"));
fields.add(baseSchema.get("url"));
HCatBaseInputFormat.setOutputSchema(job, new HCatSchema(fields));
```

22.2.2 写数据

和读数据类似，写数据时，需要指定数据库名和要写入的表的表名。如果要写入的表是分区表而只想写入其中一个分区时，那么还要指定要写入的这个分区的分区名：

```
/**
 * Initializes a new OutputJobInfo instance for writing data from a table.
 * @param databaseName the db name
 * @param tableName the table name
 * @param partitionValues The partition values to publish to, can be null or empty
Map
 */
public static OutputJobInfo create(String databaseName,
                                    String tableName,
                                    Map<String, String> partitionValues) {
    ...
}
```

databaseName表示表所在的指定的Hive数据库（或模式）的名称。如果这个值为null的话，那么就会使用默认的default数据库。而tableName表示的是要写入的目标表名。表名必须是非null的，而且应该是Hive中实际存在的一个表。partitionValues表示用户期望创建的分区名称。如果需要写入到特定的某个分区的话，那么这个map必须明确地指定这个分区。例如，如果这个表具有二级分区的话，那么在map中必须要指定这两级分区字段。对于非分区表，这个字段可以省略为

null。当以这种方式显式指定分区后，那么分区字段就没必要保存在数据文件中了。如果数据文件中包含了分区字段的内容，那么HCatalog在将数据写入到Hive前会将这些字段过滤丢弃掉，因为在Hive中是不会在数据中保存分区字段内容的。

同时向多个分区写入数据是允许的，这也就是所谓的动态分区，因为记录是在执行时动态划分到不同分区的。如果要使用动态分区，那么分区字段的值必须存在于数据中。例如，如果某张表是按照字段“datestamp”进行划分的，那么这个字段必须存在于reducer端的数据收集器中。这是因为HCatalog将读取分区字段来确定将数据写入到哪个分区去。在写数据的过程中，之前的分区字段中那些列的值将会被丢弃掉。

一旦创建好一个OutputJobInfo对象，然后就可以通过静态方法setOutput将其传递给HCatOutputFormat：

```
outputJobInfo outputInfo = OutputJobInfo.create(dbName, outputTableName, null));
HCatOutputFormat.setOutput(job, outputInfo);
```

当HCatOutputFormat写数据时，输出的键的数据类型并不重要，而值的类型必须是HCatRecord。可以在reducer阶段写数据，或者对于只有map过程的任务来说在map阶段写数据。

将上面的内容放到同一个例子中。下面的代码将会从表名为rawevents的表中读取时间戳为20120531的分区，然后对每个用户计算对应的事件个数，并将结果最终写入到表cntd中：

```
public class MRExample extends Configured implements Tool {

    public static class Map extends
        Mapper<WritableComparable, HCatRecord, Text, LongWritable> {

        protected void map(WritableComparable key,
                           HCatRecord value,
                           Mapper<WritableComparable, HCatRecord,
                           Text, LongWritable>.Context context)
                           throws IOException, InterruptedException {
            // Get our schema from the Job object.
            HCatSchema schema = HCatBaseInputFormat.getOutputSchema(context);
            // Read the user field
            String user = value.get("user", schema);
            context.write(new Text(user), new LongWritable(1));
        }
    }
}
```

```

public static class Reduce extends Reducer<Text, LongWritable,
    WritableComparable, HCatRecord> {

    protected void reduce(Text key, Iterable<LongWritable> values,
        Reducer<Text, LongWritable,
        WritableComparable, HCatRecord>.Context context)
        throws IOException ,InterruptedException {

        List<HCatFieldSchema> columns = new ArrayList<HCatFieldSchema>(2);
        columns.add(new HCatFieldSchema("user", HCatFieldSchema.Type.STRING, ""));
        columns.add(new HCatFieldSchema("cnt", HCatFieldSchema.Type.BIGINT, ""));
        HCatSchema schema = new HCatSchema(columns);

        long sum = 0;
        Iterator<IntWritable> iter = values.iterator();
        while (iter.hasNext()) sum += iter.next().getLong();
        HCatRecord output = new DefaultHCatRecord(2);
        record.set("user", schema, key.toString());
        record.setLong("cnt", schema, sum);
        context.write(null, record);
    }
}

public int run(String[] args) throws Exception {
    Job job = new Job(conf, "Example");
    // Read the "rawevents" table, partition "20120531", in the default
    // database
    HCatInputFormat.setInput(job, InputJobInfo.create(null, "rawevents",
        "datestamp='20120531'"));
    job.setInputFormatClass(HCatInputFormat.class);
    job.setJarByClass(MRExample.class);
    job.setMapperClass(Map.class);
    job.setReducerClass(Reduce.class);
    job.setMapOutputKeyClass(Text.class);
    job.setMapOutputValueClass(LongWritable.class);
    job.setOutputKeyClass(WritableComparable.class);
    job.setOutputValueClass(DefaultHCatRecord.class);
    // Write into "cntd" table, partition "20120531", in the default database
    HCatOutputFormat.setOutput(job
        OutputJobInfo.create(null, "cntd", "ds=20120531"));
    job.setOutputFormatClass(HCatOutputFormat.class);
    return (job.waitForCompletion(true) ? 0 : 1);
}

public static void main(String[] args) throws Exception {
    int exitCode = ToolRunner.run(new MRExample(), args);
    System.exit(exitCode);
}
}

```

22.3 命令行

因为HCatalog使用的是Hive的元数据存储，所以Hive用户是不需要使用其他额外的工具来访问元数据的。对于Hive用户，像以前一样使

用Hive命令行工具就可以了。不过，对于那些不是Hive用户的HCatalog用户来说，提供了一个被称为hcat的命令行工具。这个工具和Hive的命令行工具有些类似。两者最大的不同是其只接受不会产生MapReduce任务（job）的命令。这意味着其可以支持大部分的DDL（数据定义语言，用于定义数据的操作，如创建表这样的操作）语句：

```
$ /usr/bin/hcat -e "create table rawevents (user string, url string);"
```

命令行支持表22-1中所示的这些操作。

表22-1 hcat命令行选项

选项	描述	例子
-e	通过命令行执行DDL语句	hcat -e "show tables;"
-f	执行包含有DDL语句的脚本文件	hcat -f setup.sql
-g	为创建的表指定组	hcat -g mygroup ...
-p	为创建的表指定目录权限	hcat -p rwxr-xr-x ...
-D	将键-值对以Java系统属性的形式传递给HCatalog	hcat -D log.level=INFO
-h	提示用法帮助信息	hcat -h 或者 hcat

（译者注：原书中这个表描述有误，本表是修正后的内容。）

HCatalog命令行不支持如下这些SQL操作：

- SELECT
- CREATE TABLE AS SELECT
- INSERT
- LOAD

- ALTER INDEX REBUILD
- ALTER TABLE CONCATENATE
- ALTER TABLE ARCHIVE
- ANALYZE TABLE
- EXPORT TABLE
- IMPORT TABLE

22.4 安全模型

HCatalog并没有使用Hive的授权模型。不过，HCatalog的用户认证功能和Hive是完全相同的。Hive试图实现传统的数据库授权模型。不过，这在Hadoop生态系统中有一些限制。

因为是可以直接访问文件系统来获取底层数据的，所以Hive的权限控制是有限的。通过将Hive所对应的所有文件和文件夹的权限设置为执行Hive任务的用户所有这样的方式可以解决这个问题。通过这种方式可以防止其他用户读取或者写入数据，除了通过Hive进行操作。不过，这样有一个缺点，就是Hive中所有的UDF都需要以超级用户来执行，因为在Hive进程中会执行这些UDF。因此，它们都需要数据仓库中对所有文件的读和写权限。

避免这个问题的唯一方式简单地说就是要声明UDF为特权操作，而且只允许有访问权限的那些人创建UDF，尽管目前尚无机制强制这么做。在Hive中这可能是可以接受的，但是在Pig和MapReduce这些用户产生代码非常多的应用中显然就很难接受了。

为了解决这个问题，HCatalog使用和存储层相同的权限进行权限控制。对于存储在HDFS中的数据，这意味着HCatalog将使用包含有数据的文件夹和文件的属性中的用户权限来判断是否有权限进行访问。如果有权限，那么其将被赋予相同的元数据访问权限。例如，如果某个用户具有表分区路径的父目录的写权限的话，那么其也就具有的这个表的写权限。

这样做的优点是这确实是安全的，很难通过修改抽象层来推翻系统权限控制。缺点是，HDFS所支持的安全模型要比传统数据库弱得多。特别是，如字段级别的字段功能通过这种模式是无法提供的。同

时，用户只能通过将其加入到文件系统中文件对应的组中的方式来获取访问表的权限。

22.5 架构

正如前面所解释的，HCatalog对于Pig和MapReduce使用它们的标准输入和输出机制。HCatLoader和HCatStorer是相当简单的，因为它们使用的分别就是HCatInputFormat和HCatOutputFormat。这2个MapReduce类很大一部分工作就是将MapReduce和Hive元数据存储结合起来。

图22-1 展示的是HCatalog的架构图。




图22-1 HCatalog架构图

HCatInputFormat通过和Hive的元数据存储进行通信来获取要读取的表和分区的信息。这包括获取表的模式，也包括获取每个分区的模式。对于每个分区，还要确定对应的用于读取该分区数据的实际的InputFormat和SerDe。这些会被收集在一起，然后和所有的分区的数据划分一起，返回一个InputSplits对象列表。

同样地，对于每个底层的**InputFormat**都会有对应的**RecordReader**用于对划分进行解码。然后**HCatRecordReader**会通过和分区对应的**SerDe**将来自底层的**RecordReader**的值转化成**HCatRecord**。这个过程中包含有为每个分区补充对应缺少的列。也就是说，当表模式中包含有分区模式中不存在的字段时，那么就会向**HCatRecord**中增加缺少的列且值为**null**。同时，如果用户明确指定需要其中部分字段的话，那么这时就会去除掉不需要的字段。

HCatOutputFormat也会和Hive元数据存储进行通信，以确认写入的文件格式和模式。尽管**HCatalog**当前只支持表指定的存储格式，不过无需为每个分区都打开不同的**OutputFormat**。底层的**OutputFormat**已经通过**HCatOutputFormat**进行封装了。对于每个分区都会创建一个封装了底层**RecordWriter**的**RecordWriter**，尽管它们都使用相同的**SerDe**来写这些新记录。当所有的分区都写完后，**HCatalog**会使用一个**OutputCommitter**来将元数据信息写入到元数据存储中。

第23章 案例研究

全球有很多公司和组织使用Hive。本章提供的案例将详细介绍有趣的和独特的使用场景和我们面临过的问题，以及如何使用Hive这个独特的PB级别数据数据仓库来解决这些问题。

23.1 m6d.com(Media6Degrees)

23.1.1 M 6D的数据科学，使用Hive和R

——Ori Stitelman

在本案例研究中，我们考察了m6d的数据科学团队使用Hive对综合的海量数据提取信息的众多方法中的一种。m6d是一家面向展示广告的公司。我们所扮演的角色就是通过创建定制的机器学习算法来为广告宣传活动寻找最好的新前景。这些算法是用于一个交付引擎之上的，其被绑定到无数个实时竞价交易，从而提供基于用户客户端行为的和按照网络地理位置提供广告条展示的方式。m6d广告展示引擎每天都涉及到数十亿的竞价次数和进行数千万次的广告展示。自然，这样的一个系统会产生大量的数据。由本公司的广告展示交付系统产生的大部分的记录是存储在m6d公司的Hadoop集群中的，也因此，Hive是我们的科学家对这些日志进行数据分析的主要工具。

Hive为我们的科学家团队提供了提取和处理大量数据的一种方式。事实上，其允许我们分析在使用Hive之前无法进行有效分析的海量数据，并对其进行样本抽取和数据聚合。尽管事实上Hive允许我们以比之前快很多倍的速度来访问海量数据，但其并不能改变这样一个事实，那就是，以前我们所熟悉的数据科学家并不能以所产生的所有数据作为样本数据进行样本分析，也就是对全局数据进行分析而不是抽样分析。总之，Hive为我们提供了一个提取海量数据的很好的工具。不过，数据科学家在数据科学领域使用的方法工具箱、或在统计学习领域所使用的方法如果不经过实质性的改变的话，则是无法轻易适用于海量数据集分析的。

目前已经有了或者正在开发各种各样的软件包，来对海量数据集进行启发式的和非启发式的知识学习。这些软件中有一些是独立的软件实现，例如Vowpal Wabbit 和BBR，而其他一些是基于像HadoopMahout这样的大型基础架构或其他众多的针对R的“海量数据”处理包进行实现的。这些算法一部分是利用并行编程方法实现的，而其他则是依赖于不同的方法来实现可伸缩性的。

我们团队的几个数据科学家对于统计学习使用的主要工具是R。R提供了众多的包来支持众多的统计算法。更重要的是，我们对于R具有很多的经验，我们知道其是如何执行的，并了解它们的特性，而且非常熟悉其技术文档。不过，R的一个主要缺点是，默认情况下其需要将所有的数据集载入到内存中。这是一个主要的限制。还有就是，一旦R中的数据比可以载入内存的数据要大时，系统就会出现内存交换，导致系统抖动并显著降低处理速度^[1]。

我们并不倡导不使用可以使用的新工具。很明显，利用好这些可伸缩技术是非常重要的，但是我们只能有那么多的时间对新技术进行调查和测试。所以现在我们只剩下一个选择，要么对数据进行采样来适应我们更熟悉的工具，要么使用可以用于海量数据分析的新工具。如果我们决定使用新工具的话，那么我们就可以分析更多的数据，因此也就可以降低我们的估算误差。这是非常有吸引力的。对于那些要求结果精确的情况来说这种方式是非常吸引人的。不过，学习使用新工具需要时间成本，也因需要时间学习新工具而不能够去解决其他对公司有价值的问题。

一种替代方式就是我们可以对数据进行向下抽样，以便可以使用我们手头上的旧工具进行分析。不过这样我们需要处理一定的精度损失，会增加我们的估算误差。不过，这样我们就能以我们熟悉的工具来进行数据处理了。因此也就能保持使用我们当前的工具箱，不过会丢失一些精准度。然而，并非只有这两种可行的方法。在本案例研究中，我们推荐一种既能够保持现有工具箱的功能，同时又能在使用更大的样本数据集或整个数据集时保证计算精度或减小误差的方式。

图23-1展示了为某个广告排名设计的算法得出的值的分布情况。更高的分数表示具有更高概率的转换。本图清楚地表明，较高分数的转化率要比较低分数段的转化率低。也就是，分数在1以上的比分数在0.5和1之间的转化率要低。考虑到某些活动只有目标比例非常小的用户群，因此具有最好前景的是最顶端的得分者。




图23-1 转换率和得分的概率

图23-1中这条表示分数和转换率之间关系的曲线是使用统计编程包R中的广义相加模型（GAM）[\[2\]](#)生成的。这里就不对GAM进行详细的介绍了。这个案例研究的目的可以认为是一个黑盒，其可以预测出每个分数的转换率。浏览器则可以根据预测的转换率重新进行排名，这样，预测的转换率就变成了新的分数。

可以通过下面的方式来产生新的排名。首先，需要为每个浏览器提取分数，然后在设定的一段时间内跟踪它们，例如5天，并记录下它们所需的动作，然后进行转换。假设Hive中有张名为scoretable的表，其具有表23-1所示的信息，并按照date和offer进行分区。

表23-1 样例表scoretable中的字段信息

名称	类型	描述
score	double	由初始算法产生的分数，这个分数没有合理排序
convert	int	转换的变量是一个二进制变量，其值为1，如果独立浏览在随后5天内执行了指定的动作；反之如果没有执行，则其值为0
date	int	浏览被赋予特定分数的日期
offer	int	一次出现的ID

下面这个查询语句可以用于从表scoretable中抽取一组数据，用于在R中生成GAM曲线，来预测前面所述表中不同级别分数的预测转换率：

```
SELECT score,convert
FROM scoretable
WHERE date >= (...) AND date <= ...
AND offer = (...);
1.2347 0
3.2322 1
0.0013 0
0.3441 0
```

然后通过如下代码将这些数据加载到R中，再使用前面所提的表的数据生成预测转换率曲线：

```
library(mgcv)
g1=gam(convert~s(score),family=binomial,data=[data frame name])
```

这种方式存在一个问题，那就是只能使用有限几天的数据来进行分析。因为一旦使用的数据集太大，甚至只要取稍微大于3天的数据就会导致R无法稳定工作。此外，如果要处理3天的数据量，每次执行都需要10分钟的时间进行初始化。因此，对于一个的计分算法，3天的数据对于大约300个竞价分析来说大约需要消耗50个小时。

使用一个稍微不同的方式，通过简单地从Hive中提取数据，并利用mgcv中提供的gam函数的允许频率权重的功能，同样的分析可以使

用更多的数据，获取更多的信息，而执行速度可以更快。通过在Hive中获取分数的最近近似值，并为每个最近近似值估算一个频率权重，通过**GROUP BY**语句进行转换组合。这是处理大数据集的通用方式，而且这里面并不会因为四舍五入近似关系导致结果信息的不准确，因为没有理由认为，个体分数间相差0.001会有任何的不同。如下这个查询语句将产生这样一个数据集：

```
SELECT round(score,2) as score,convert,count(1) AS freq
  FROM scoretable
 WHERE date >= [start.date] and date <= [end.date] and offer = [chosen.offer]
  GROUP BY round(score,2),convert;
1.23 0 500
3.23 1 22
0.00 0 127
0.34 0 36
```

这种方式产生的结果数据集比之前那种没有使用频率权重的方式产生的数据集要小得多。事实上，每个提供的初始数据集都含有数百万条记录，而这个新数据集相对每个提供的数据集缩小到了6 500条。这样可以通过如下的命令将新数据集载入到R中并产生新的GAM结果：

```
library(mgcv)
g2=gam(convert~s(score),family=binomial,weights=freq,
       data=[frequency weight data frame name])
```

前面对于仅仅3天的数据每份提供的数据集创建GAM就需要10分钟的时间，而后者使用频率权重的方式可以在10秒钟左右处理基于7天的数据的GAM计算。因此，通过使用频率权重，对于300个估价，使用之前的方式需要50小时，而使用新的方法后只需要50秒。同时增加的速度也允许使用超过两倍的数据获得更加精确的预测转换概率。总之，频率权重方式可以在很少的时间内获得更精确的GAM预测估算值。

在当前的案例研究中，我们展示了如何通过对连续变量取近似值和使用频率权重进行分组，我们既可以通过使用更多的数据获得更精确的估值，又能消耗更少的计算资源，最终可以最快地进行估算。这个例子只展示了只有单一功能，按照分数计算的模型。一般来说，这种方式适用于低数据特性或者较大数据量的稀疏特性。上述的方法可以扩展到高维问题，但需要使用其他一些小技巧。处理高维问题的一个方法就是对变量或者特性进行分桶，转换成二进制变量后，再使用**GROUP BY**进行查询，并对这些特性计算频率权重。然而，随着功

能数量的增长，这些功能特性并不稀疏，再使用这种方式几乎就没有什么价值了，这时就需要寻找其他的解决办法，或者是可以处理这种大数据集的工具。

23.1.2 M6D UDF伪随机

——David Ha 和 Rumi Patel

对数据进行排序然后获取最大的 N 个值，这种需求很直截了当。用户对整个数据集基于某些标准进行排序，然后限制结果集为 N 条。但有些时候需要对元素进行分组，然后保留每个分组中的排序后的前 N 条记录。例如，计算每名歌词艺术家的排名前10的歌曲，或者按照商品类别和国家得到最畅销的前100种商品。很多的数据库平台都提供了一个名为rank()的函数，其适用于这些使用场景。在Hive中我们可以通过实现用户自定义函数来达到同样的目的。我们将这个函数命名为p_rank()，这样可以和Hive中使用的rank()有所区别。

假设我们有如表23-2所示的商品销售数据，我们希望查看按照类别和国家的前3名畅销的商品：

表23-2 样例表p_rank_demo中的数据内容

类别	国家	商品名称	销售数量
movies	us	chewblanca	100
movies	us	war stars iv	150
movies	us	war stars iii	200
movies	us	star wreck	300
movies	gb	titanus	100

类别	国家	商品名称	销售数量
movies	gb	spiderella	150
movies	gb	war stars iii	200
movies	gb	war stars iv	300
office	us	red pens	30
office	us	blue pens	50
office	us	black pens	60
office	us	pencils	70
office	gb	rulers	30
office	gb	blue pens	40
office	gb	black pens	50
office	gb	binder clips	60

在大多数系统中，如下SQL都是可以执行的：

```

SELECT
  category, country, product, sales, rank
FROM (
  SELECT
    category, country, product, sales,
    rank() over (PARTITION BY category, country ORDER BY sales DESC) rank
  FROM p_rank_demo) t
WHERE rank <= 3
  
```

如果想通过HiveQL获得相同的结果，那么第一步就需要将数据分成组。我们可以使用DISTRIBUTE BY语句进行分组。我们需要保证具有相同类别和国家的记录都发送到同一个reducer上：

```
DISTRIBUTE BY
category,
country
```

下一步就是使用SORT BY语句对每组数据按照销量降序排列。因为ORDER BY会触发全局数据排序，所以SORT BY所涉及的数据会在同一个特定的reducer中进行排序。这里需要重新写上DISTRIBUTE BY语句中的划分列名：

```
SORT BY
category,
country,
sales DESC
```

将所有内容都放在一起，就是如下这个样子：

```
ADD JAR p-rank-demo.jar;
CREATE TEMPORARY FUNCTION p_rank AS 'demo.PsuedoRank';

SELECT
category, country, product, sales, rank
FROM (
SELECT
category, country, product, sales,
p_rank(category, country) rank
FROM (
SELECT
category, country, product,
sales
FROM p_rank_demo
DISTRIBUTE BY
category, country
SORT BY
category, country, sales desc) t1) t2
WHERE rank <= 3
```

子查询t1重新组织数据，以保证相同的商品类别和国家下的数据按照销售数量降序排列。第2个查询t2会使用到p_rank()函数，并将其命名为rank，其对于每组中的行都会增加一个排名。最外层的查询会限制只保留排名前三的值。经排序后的结果如表23-3所示。

表23-3 对样例表p_rank_demo进行RANK排序后的数据内容

类别	国家	商品名称	销售数量	RANK 序号
movies	gb	war stars iv	300	1
movies	gb	war stars iii	200	2
movies	gb	spiderella	150	3
movies	us	star wreck	300	1
movies	us	war stars iii	200	2
movies	us	war stars iv	150	3
office	gb	binder clips	60	1
office	gb	black pens	50	2
office	gb	blue pens	40	3
office	us	pencils	70	1
office	us	black pens	60	2
office	us	blue pens	50	3

这里是以原生UDF的方式实现p_rank()函数的，其参数都是确定的组属性，在本例中，就是类别和国家。这个函数可以记住上一次的参数值，因此只要成功和参数匹配，就会一直增加数值并返回排列值。

一旦和参数不匹配，这个函数就会重置排列值为1，然后重新开始计算。

这仅是个说明如何使用p_rank()函数的简单的例子。用户当然也可以按照类别和国家获取最畅销的第10位到第15位的商品。或者，用户已经计算好了每个商品类别和国家下的商品的个数，那么用户也可以结合JOIN使用p_rank()计算百分比。例如，假设在“movies（电影）”和“us（美国）”组下面有1000种产品，那么第50名、第70名和第95名的RANK值就分别对应于500、700和950。这里需要明确的是，p_rank()并非是rank()函数的替代函数，因为两者在某些情形下是有差异的。例如，对于相同的值，rank()函数返回的值是相同的，但是p_rank()函数仍然会进行累加计算，因此具体使用需要按照期望选择并在数据上进行测试。

下面展示的是具体的代码实现。这份代码是属于公共领域的，所以用户可以随意使用、改进和修改它，以满足个人的需求：

```
package demo;

import org.apache.hadoop.hive.ql.exec.UDFArgumentException;
import org.apache.hadoop.hive.ql.metadata.HiveException;
import org.apache.hadoop.hive.ql.udf.generic.GenericUDF;
import org.apache.hadoop.hive.serde2.objectinspector.ObjectInspector;
import org.apache.hadoop.hive.serde2.objectinspector.primitive.
    PrimitiveObjectInspectorFactory;

public class PsuedoRank extends GenericUDF {
    /**
     * The rank within the group. Resets whenever the group changes.
     */
    private long rank;

    /**
     * Key of the group that we are ranking. Use the string form
     * of the objects since deferred object and equals do not work
     * as expected even for equivalent values.
     */
    private String[] groupKey;

    @Override
    public ObjectInspector initialize(ObjectInspector[] oi)
        throws UDFArgumentException {
        return PrimitiveObjectInspectorFactory.javaLongObjectInspector;
    }

    @Override
    public Object evaluate(DeferredObject[] currentKey) throws HiveException {
        if (!sameAsPreviousKey(currentKey)) {
            rank = 1;
        }
    }
}
```

```

        return new Long(rank++);
    }

    /**
     * Returns true if the current key and the previous keys are the same.
     * If the keys are not the same, then sets {@link #groupKey} to the
     * current key.
     */
    private boolean sameAsPreviousKey(DeferredObject[] currentKey)
        throws HiveException {
        if (null == currentKey && null == groupKey) {
            return true;
        }
        String[] previousKey = groupKey;
        copy(currentKey);
        if (null == groupKey && null != previousKey) {
            return false;
        }
        if (null != groupKey && null == previousKey) {
            return false;
        }
        if (groupKey.length != previousKey.length) {
            return false;
        }
        for (int index = 0; index < previousKey.length; index++) {
            if (!groupKey[index].equals(previousKey[index])) {
                return false;
            }
        }
        return true;
    }

    /**
     * Copies the given key to {@link #groupKey} for future
     * comparisons.
     */
    private void copy(DeferredObject[] currentKey)
        throws HiveException {
        if (null == currentKey) {
            groupKey = null;
        } else {
            groupKey = new String[currentKey.length];
            for (int index = 0; index < currentKey.length; index++) {
                groupKey[index] = String.valueOf(currentKey[index].get());
            }
        }
    }

    @Override
    public String getDisplayString(String[] children) {
        StringBuilder sb = new StringBuilder();
        sb.append("PsuedoRank ");
        for (int i = 0; i < children.length; i++) {
            if (i > 0) {
                sb.append(", ");
            }
            sb.append(children[i]);
        }
        sb.append(")");
    }
}

```

```
    return sb.toString();
}
```

23.1.3 M6D如何管理多MapReduce集群间的Hive数据访问

尽管Hadoop集群规模可以设计成10到10 000个节点，但是有时特定的部署需求会涉及要在不止一个文件系统或者JobTracker上运行任务。在M6D中，我们有这样的需求，例如我们有一些需要Hadoop和Hive在每小时或每天都可以按时完成的关键业务报告。不过我们的系统也支持数据科学家和销售工程师定期执行的一些特定报告。尽管使用公平调度器和能力调度器已经满足了我们的大部分需求，我们仍需要更高的调度隔离。同时，因为HDFS没有快照或者增量备份功能特性，我们因此需要一个对应的解决方案来防止意外的数据删除或者意外的删除表操作进而避免数据丢失。

我们的解决方案就是运行2个独立的Hadoop集群。在主集群上，数据可以被设置为2份或者3份数据冗余，而且同时会被复制到第2个集群上。这种方式可以保证我们对于时效性强的需求还可以有足够的资源同时提供给临时用户进行使用。此外，我们可以防止任何意外删除表或数据的情况。这种方式确实会增加部署和管理2个集群的开销，而这种开销在我们的使用场景下是合理的。

我们的2个集群分别被称为生产环境和研究环境。其都具有各自的专有数据节点（DataNode）和任务节点（TaskTracker）。每个NameNode和JobTracker节点都是DRBD和Linux-HA的故障恢复方案。这2个集群都是部署在同一个交换网络的（见表23-4和表23-5）。

表23-4 生产环境配置

NameNode	hdfs.hadoop.pvt:54310
JobTracker	jt.hadoop.pvt:54311

表23-5 探索环境

NameNode	rs01.hadoop.pvt:34310
JobTracker	rjt.hadoop.pvt:34311

1. 使用Hive执行跨集群查询

生产集群上存在一张名为zz_mid_set的表，但是我们期望不使用distcp命令就可以在研究集群上查询这张表。通常来说，我们会尽量避免这样的操作，因为其破坏了我们的隔离设计，但是很高兴地是，这样的操作是可以做到的。

通过describe extended命令除了可以查看表具有的字段信息外还可以查看其实际存储的HDFS路径：

```
hive> set fs.default.name;
fs.default.name=hdfs://hdfs.hadoop.pvt:54310
hive> set mapred.job.tracker;
mapred.job.tracker=jt.hadoop.pvt:54311
hive> describe extended zz_mid_set;
OK
adv_spend_id      int
transaction_id    bigint
time              string
client_id         bigint
visit_info        string
event_type        tinyint
level             int

location:hdfs://hdfs.hadoop.pvt:54310/user/hive/warehouse/zz_mid_set
Time taken: 0.063 seconds
hive> select count(1) from zz_mid_set;
1795928
```

在第2个集群上，使用CREATE TABLE语句创建相同的表，表的类型需要是外部表（EXTERNAL），这样即使在第2个集群上执行了删除表操作，也不会真实地删除第1个表中的数据。需要注意的是，这里我们需要指定完整的URL路径。事实上，当用户通过相对路径来指定表存储路径时，Hive实际会在元数据库中存储完整的URL路径：

```
hive> set fs.default.name;
fs.default.name=hdfs://rs01.hadoop.pvt:34310
hive> set mapred.job.tracker;
mapred.job.tracker=rjt.hadoop.pvt:34311
hive> CREATE TABLE EXTERNAL table_in_another_cluster
( adv_spend_id int, transaction_id bigint, time string, client_id bigint,
visit_info string, event_type tinyint, level int)
LOCATION 'hdfs://hdfs.hadoop.pvt:54310/user/hive/warehouse/zz_mid_set';
hive> select count(*) FROM table_in_another_cluster;
1795928
```

需要注意的是，之所以这样的跨集群操作可以工作，是因为两个集群的网络是相通的。我们所提交的任务所在的TaskTracker节点需要能够访问另一个集群的NameNode节点和所有的DataNode节点。Hadoop的设计理念中有一项就是转移计算而不转移数据，就是将计算尽量地

转移到数据所在的位置。通过调度将计算任务转移到数据所在的节点上。在这种情况下，TaskTracker会连接另一个集群的DataNode。这就意味着会造成通用性能下降和网络占用增加。

2. 不同集群间的Hive数据冗余

对于Hadoop和Hive而言保持数据冗余要比传统关系型数据库容易得多。和传统数据库在执行多事务时会频繁改变底层数据不同，Hadoop和Hive中的数据通常是“一次写入的”。增加新分区不会影响到已经存在的其他分区，而且通常来说，是按照时间日期来增加新分区的。

我们早期所使用的备份系统是一个独立的系统，也就是使用distcp命令进行操作，然后按照一定的时间间隔使用生成的Hive语句来增加分区。当我们想备份一张新表时，我们就会先拷贝来一份已有的代码，然后修改下这个脚本的配置来处理新的表和分区。经过一段时间，我们制定了一个可以更加自动化对表和分区进行备份的系统。

这个处理过程在创建分区的同时会创建一个空的HDFS文件，名为：

```
/replication/default.fracture_act/hit_date=20110304,mid=3000
```

备份进程会不断地扫描需要备份的目录结构。如果其发现一个新的文件，那么就会在Hive元数据库中查找其对应的表和分区，然后使用查找结果来备份这个分区。成功备份后这个文件就会被删除掉。

如下的代码片段就是这个程序的主循环处理部分。首先，我们会做一些检查来确保表是存在于目标元数据存储中：

```
public void run(){
    while (goOn){
        Path base = new Path(pathToConsume);
        FileStatus [] children = srcFs.listStatus(base);
        for (FileStatus child: children){
            try {
                openHiveService();
                String db = child.getPath().getName().split("\\\\.")[0];
                String hiveTable = child.getPath().getName().split("\\\\.")[1];
                Table table = srcHive.client.get_table(db, hiveTable);
                if (table == null){
                    throw new RuntimeException(db+" "+hiveTable+
                        " not found in source metastore");
                }
            }
        }
    }
}
```

```

    }
    Table tableR = destHive.client.get_table(db, hiveTable);
    if (tableR == null){
        throw new RuntimeException(db+" "+hiveTable+
            " not found in dest metastore");
    }
}

```

通过数据库名和表名我们就可以在元数据存储中找到其对应的存储路径信息。之后，我们会做一个检查来保证这个信息并非已经存在：

```

URI localTable = new URI(tableR.getSd().getLocation());
FileStatus [] partitions = srcFs.listStatus(child.getPath());
for (FileStatus partition : partitions){
    try {
        String replaced = partition.getPath().getName()
            .replace(", ", "/").replace("'", "");
        Partition p = srcHive.client.get_partition_by_name(
            db, hiveTable, replaced);
        URI partUri = new URI(p.getSd().getLocation());
        String path = partUri.getPath();
        DistCp distCp = new DistCp(destConf.conf);
        String thdfile = "/tmp/replicator_distcp";
        Path tmpPath = new Path(thdfile);
        destFs.delete(tmpPath,true);
        if (destFs.exists( new Path(localTable.getScheme()+
            "://" + localTable.getHost() + ":" + localTable.getPort() +
            path) ) ){
            throw new RuntimeException("Target path already exists "
                + localTable.getScheme() + "://" + localTable.getHost() +
                ":" + localTable.getPort() + path );
        }
    }
}

```

Hadoop的DistCP并不适合通过编程的方式来运行。不过，我们可以传递一组字符串数据给其主函数。然后通过其返回值是否是0来判断是否成功执行：

```

String [] dargs = new String [4];
dargs[0]= "-log";
dargs[1]= localTable.getScheme() + "://" + localTable.getHost() + ":" +
    localTable.getPort() + thdfile;
dargs[2]= p.getSd().getLocation();
dargs[3]= localTable.getScheme() + "://" + localTable.getHost() + ":" +
    localTable.getPort() + path;
int result = ToolRunner.run(distCp, dargs);
if (result != 0){
    throw new RuntimeException("DistCP failed " + dargs[2] +
        "+dargs[3]);
}

```

最后，我们拼接好ALTER TABLE语句来增加分区：

```
String HQL = "ALTER TABLE "+hiveTable+
    " ADD PARTITION ("+partition.getPath().getName()
    +") LOCATION '"+path+"'";
destHive.client.execute("SET hive.support.concurrency =false");
destHive.client.execute("USE "+db);
destHive.client.execute(HQL);
String [] results=destHive.client.fetchAll();
srcFs.delete(partition.getPath(),true);
} catch (Exception ex){
    ex.printStackTrace();
}
} // for each partition
} catch (Exception ex) {
//error(ex);
ex.printStackTrace();
}
} // for each table
closeHiveService();
Thread.sleep(60L*1000L);
} // end run loop
} // end run
```

23.2 Outbrain

——David Funk

Outbrain是领先的内容发现平台。

23.2.1 站内线上身份识别

有时，当用户想查看网站的流量情况时，很难弄清楚这些流量实际来源于哪里，特别是来源于用户网站之外的流量情况。如果用户的网站具有很多结构不同的URL的话，那么就无法简单地将所有的链接URL和用户登录页面进行匹配。

1. 对URL进行清洗

我们期望达到的目的就是可以将链入的链接分成站内的、直接链入的或其他3个分组。如果所属组类型是其他的话，那么我们将仅仅保存原始的URL链接。这样，就可以将像对用户站点进行的Google搜索这样的链接从网站流量中区分出来，等等。如果链入的链接是空的或者值为null，那么我们将其标记为直接链入的那组。

从现在开始，我们将假定所有的URL网址都已经解析到主机名或域名了，而无论用户目标具体到什么级别的粒度。就我个人而言，我喜欢使用域，因为它更简单。据说，Hive只有一个主机名函数，但不是域名函数。

如果你只有原始URL，则有几个选项可供选择。通过HOST选项，正如下面例子所展示的，可以是个给出的链接中完整的主机名，如news.google.com或www.google.com，而其中的域名将缩短到最低的逻辑层次，像google.com或google.com.uk。

```
Host = PARSE_URL(my_url, 'HOST')
```

也许用户正在使用一个UDF来处理这种情况。不管怎样，我并不在乎。重要的是我们要使用这些来进行匹配，所以用户需要根据自己的使用场景来做出最合适的选择。

2. Determining referrer type

因此，回到这个例子。比方说，我们有3个网站：mysite1.com、mysite2.com和mysite3.com。现在，我们可以把每个页面的URL转换成适当的类别。我们假设有一个表，表名为referrer_identification，其字段如下：

```
ri_page_url STRING  
ri_referrer_url STRING
```

现在，我们可以很容易地通过如下查询来添加链接类型：

```
SELECT ri_page_url, ri_referrer_url,  
CASE  
  WHEN ri_referrer_url is NULL or ri_referrer_url = '' THEN 'DIRECT'  
  WHEN ri_referrer_url is in ('mysite1.com', 'mysite2.com', 'mysite3.com') THEN  
  'INSITE'  
  ELSE ri_referrer_url  
END as ri_referrer_url_classed  
FROM  
referrer_identification;
```

3. Multiple URL

这都是非常简单的。但是如果我们使用的是一个广告网络呢？如果我们有成百上千的网站呢？如果每个站点可以有任意数量的URL结构

呢?

如果是这样的话, 我们可能也有一个包含每个URL的表, 以及它属于什么类型的网站。让我们将这张表命名为site_url, 其有如下2个字段:

```
su_site_id INT
su_url STRING
```

让我们为之前的那张表referrer_identification添加一个新的字段:

```
ri_site_id INT
```

现在我们开始讨论这个问题。我们要做的是通过每个链入网址, 看它是否与任何相同的站点ID匹配。如果是匹配的话, 那么这是一个站内链接, 否则不是站内链接。所以, 让我们通过如下查询进行确认:

```
SELECT
  c.c_page_url as ri_page_url,
  c.c_site_id as ri_site_id,
  CASE
    WHEN c.c_referrer_url is NULL or c.c_referrer_url = '' THEN 'DIRECT'
    WHEN c.c_insite_referrer_flags > 0 THEN 'INSITE'
    ELSE c.c_referrer_url
  END as ri_referrer_url_classed
FROM
  (SELECT
    a.a_page_url as c_page_url,
    a.a_referrer_url as c_referrer_url,
    a.a_site_id as c_site_id,
    SUM(IF(b.b_url <> '', 1, 0)) as c_insite_referrer_flags
  FROM
    (SELECT
      ri_page_url as a_page_url,
      ri_referrer_url as a_referrer_url,
      ri_site_id as a_site_id
    FROM
      referrer_identification
    ) a
    LEFT OUTER JOIN
    (SELECT
      su_site_id as b_site_id,
      su_url as b_url
    FROM
      site_url
    ) b
    ON
      a.a_site_id = b.b_site_id and
      a.a_referrer_url = b.b_url
  ) c
```

对于这个查询语句有几点需要说明。在本例中，我们使用的是外连接，因为我们希望有一些外部链入链接不与其匹配，这将让它们通过。因此，我们只会抓住确实匹配的条目，如果有任何这样的链接，我们知道它们来自网站内的某处。

23.2.2 计算复杂度

假设用户要计算用户网站、网络或其他什么东西的独立访客数量的话。我们将使用一个非常简单的假想表daily_users来表示：

```
du_user_id STRING
du_date STRING
```

不过，如果有非常多的用户而且集群中又没有足够的机器的话，那么在集群中计算一个月的用户数据都会变得非常困难：

```
SELECT
  COUNT(DISTINCT du_user_id)
FROM
  daily_users
WHERE
  du_date >= '2012-03-01' and
  du_date <= '2012-03-31'
```

在所有的可能性中，如果用户集群没有太多问题，则可以使其通过map阶段，但是在reduce阶段就会出现问题。问题就是，它能够访问所有的记录，但却不能同时对其进行计数。当然，用户也不能每天都对其进行计算，因为这样做可能会有些多余。

1. 为什么这是个问题

计数复杂度是 $O(n)$ ，其中 n 是记录的数量，但它有一个比较高的常数因子。我们可能会想出一些聪明的切割方式，来稍微降低一点计算复杂度，但更容易的方式就是减小 n 的值。虽然有一个高 $O(n)$ 并不好，但大多数真正的问题出现在后面。如果用户处理某个问题需要运行的时间是 $n^{1.1}$ ，那么谁在乎如果 $n = 2$ 还是 $n = 1$ 呢。这样确实会较之前慢，但远远没有 $n=1$ 和 $n=100$ 之间的区别那么大。

所以，如果假设每天都有 m 条数目，而平均冗余是 x 的话，那么我们的第1个查询将是 $n=31*m$ 条记录。我们通过创建一个用来保存每天重複版本的临时表将查询记录减少到 $n=31*(m-x)$ 。

2. 加载一个临时表

首先，创建临时表：

```
CREATE TABLE daily_users_deduped (dud_user_id STRING)
PARTITIONED BY (dud_date STRING)
ROW FORMAT DELIMITED
FIELDS TERMINATED BY '\t';
```

然后我们写一个每天都可以执行一次的查询模板版本，然后使用它来更新我们的临时表。我一般将这些操作称为“metajobs”，所以我们可以称为mj_01.sql：

```
INSERT OVERWRITE TABLE daily_users_deduped
PARTITION (dud_date = ':date:')

SELECT DISTINCT
  du_user_id
FROM
  daily_users
WHERE
  du_date = ':date:'
```

接下来，我们写一个脚本，来替换组装这个文件，然后再在指定的日期范围内运行这个脚本。为此，我们需要涉及到3个函数，分别为：modify_temp_file函数，其用于替换一个变量；fire_query函数，其实质上就是对指定文件执行hive - f命令；最后一个函数是delete，用于删除文件。

```
start_date = '2012-03-01'
end_date = '2012-03-31'

for date in date_range(start_date, end_date):
    temp_file = modify_temp_file('mj_01.sql', {':date': ':my_date'})
    fire_query(temp_file)
    delete(temp_file)
```

3. 查询临时表

运行这个脚本，然后就可以得到一个 $n=31*(m-x)$ 大小的表。现在，就无需一个大的reduce执行过程就可以查询这个表了。

```
SELECT
  COUNT(DISTINCT (dud_uuid))
FROM
  daily_users_deduped
```

如果这还不够的话，那么还可以按照日期来去重，也许可以每次两个日期，而不管时间间隔是多少。如果仍然有困难，那么还可以根据用户ID将记录散列到不同类，也许可以基于用户ID的第一个字符，进一步缩小 n 的值。

基本思路是，如果可以将 n 缩小的话，那么高 $O(n)$ 也没有什么大不了的。

23.2.3 会话化

为了分析网络流量，我们常常希望能够基于各种各样的标准来测量热度。一种方法就是将用户行为分解到会话中，一次会话代表单一的一次“使用”所包含的一系列操作。一个用户在一天内或者一月中的某几天可以多次访问某个网站，但每一次访问肯定是不一样的。

那么，什么是一个会话呢？一种定义是指相隔不超过30分钟的一连串的活动就是一个会话。也就是说，如果你去你的第1个页面，等待5分钟，然后去第2个页面，那么这是相同的会话。等待30分钟后再到第3页，仍然是相同的会话。等待31分钟跳转到第4页，这次会话将被打破了，这将不是第4个访问页面了，而是第2个会话中的第1个页面。

一旦我们获得这些中断信息，我们就可以查看会话的属性信息，来看看发生了什么事而导致中断的。常规的方式就是通过会话长度来对链入的页面进行比较。所以，我们可能需要查清楚谷歌或Facebook是否给予这个网站更好的热点，这也许可以通过会话长度来进行测量。

乍一看，这似乎是一个完美的迭代过程。对于每个页面，保持倒计数，直到你找到第1个页面。但Hive是不支持迭代的。

不过，还是可以解决这个问题的。我想将这个处理过程分为4个阶段。

- ① 识别哪些页面浏览量是会话初始者，或“起源”页面。
- ② 对于每个页面，将其划分到正确的来源页面。
- ③ 将所有的页面浏览量聚合到每个来源页面。

④ 对每个来源页面进行标记，然后计算每个会话的热度。

这种方式将产生一个表，其中每一行都表示一个完整的会话，然后用户就可以查询任何想知道的信息了。

1. 设置

首先定义表session_test的字段如下：

```
st_user_id STRING
st_pageview_id STRING
st_page_url STRING
st_referrer_url STRING
st_timestamp DOUBLE
```

这些内容都很简单，不过我需要提一下st_pageview_id表示的每个事物（在这种情况下就是一个页面）的唯一ID。否则，多次查看完全相同的页面可能会令人比较困惑。本示例中，时间戳以秒为单位。

2. 找到来源页面浏览量

好的，下面让我们开始第一步（令人震惊吧！）。首先看看我们是如何找到这页面浏览会话的起始页面的。好吧，如果我们假定任何超过30分钟的停留就意味着一个新会话的话，那么任意的会话起始页都不可能停留超过30分钟或更少的时间。这是一个典型的案例总结条件。我们要做的就是，计算每个访问页面的次数。然后，任何计数为零的页面就一定是一个起始页面。

为了能做到这一点，我们需要比较所有可能在这个页面之前的页面。这是一个代价非常大的操作，因为它需要执行一个笛卡尔交叉乘积。为了防止数据膨胀到不可收拾的大小，我们应该使用尽可能多的约束条件来限制数据量。在当前情况下，限制条件只有用户ID，但是如果用户有一个包含众多独立站点的大型网络的话，那么还可以按照每个源进行分组：

```
CREATE TABLE sessionization_step_one_origins AS
SELECT
  c.c_user_id as sssoo_user_id,
  c.c_pageview_id as sssoo_pageview_id,
  c.c_timestamp as sssoo_timestamp
FROM
  (SELECT
```

```

a.a_user_id as c_user_id,
a.a_pageview_id as c_pageview_id,
a.a_timestamp as c.c_timestamp,
SUM(IF(a.a_timestamp + 1800 >= b.b_timestamp AND
      a.a_timestamp < b.b_timestamp, 1, 0)) AS c_nonorigin_flags
FROM
(SELECT
  st_user_id as a_user_id,
  st_pageview_id as a_pageview_id,
  st_timestamp as a_timestamp
FROM
  session_test
) a
JOIN
(SELECT
  st_user_id as b_user_id,
  st_timestamp as b_timestamp
FROM
  session_test
) b
ON
  a.a_user_id = b.b_user_id
GROUP BY
  a.a_user_id,
  a.a_pageview_id,
  a.a_timestamp
) c
WHERE
  c.c_nonorigin_flags

```

这个SQL可能有点长。不过其中重要的部分是计算是否是起始页码的计数器，也就是我们定义的**define c_nonorigin_flags**。基本上，计算过程如下行所示：

```

SUM(IF(a.a_timestamp + 1800 >= b.b_timestamp AND
      a.a_timestamp < b.b_timestamp, 1, 0)) as c_nonorigin_flags

```

我们将其进行分解，一部分一部分进行介绍。首先，从子查询a开始。我们使用别名b表示那些候选数据。因此，第一部分，其中的**a.a_timestamp+1800 >= b.b_timestamp**，表示候选数据时间戳不能比限定的时间戳早30分钟；第二部分，**a.a_timestamp < b.b_timestamp**这段SQL片段表示候选时间戳比限定时间戳值要大，这是一个检查过程，如果不通过则返回**FALSE**。同时，因为这是个交叉运算，因为不能使用候选时间戳作为自己的限定时间戳，否则返回**FALSE**。

现在，产生表**sessionization_step_one_origins**，其字段信息如下：

```

ssoo_user_id STRING
ssoo_pageview_id STRING

```

```
ssoo_timestamp DOUBLE
```

3. 将PV分桶到起始页面中

开始第2步的一个好的理由就是，我们需要找到某个页面所属的起始页面。做法很简单，每个页面的起始页面必定是其之前的最近的页面。为此，我们进行另外一个大的表连接操作来检查页面时间戳和所有潜在的起始页面间的最小差值：

```
CREATE TABLE sessionization_step_two_origin_identification AS

SELECT
  c.c_user_id as sstoi_user_id,
  c.c_pageview_id as sstoi_pageview_id,
  d.d_pageview_id as sstoi_origin_pageview_id
FROM
(SELECT
  a.a_user_id as c_user_id,
  a.a_pageview_id as c_pageview_id,
  MAX(IF(a.a_timestamp >= b.b_timestamp, b.b_timestamp, NULL)) as c_origin_timestamp
FROM
(SELECT
  st_user_id as a_user_id,
  st_pageview_id as a_pageview_id,
  st_timestamp as a_timestamp
FROM
  session_test
) a
JOIN
(SELECT
  ssoo_user_id as b_user_id,
  ssoo_timestamp as b_timestamp
FROM
  sessionization_step_one_origins
) b
ON
  a.a_user_id = b.b_user_id
GROUP BY
  a.a_user_id,
  a.a_pageview_id
) c
JOIN
(SELECT
  ssoo_usr_id as d_user_id,
  ssoo_pageview_id as d_pageview_id,
  ssoo_timestamp as d_timestamp
FROM
  sessionization_step_one_origins
) d
ON
  c.c_user_id = d.d_user_id and
  c.c_origin_timestamp = d.d_timestamp
```

这里还有很多内容要讲。首先，让我们看看如下这行语句：

```
MAX(IF(a.a_timestamp >= b.b_timestamp, b.b_timestamp, NULL)) as c_origin_timestamp
```

我们再次使用约束值和候选值的思路进行计算。在这种情况下，**b**是每一个约束值[a](#)的候选值。一个起始候选值是不会比页面访问的时间晚的，所以对于这类情况，我们期望找到符合标准的最新起始页。其中null值是无关紧要的，因为我们要保证获取一个最低值，总是有至少一个可能的起始页面的(即使是这个页面本身)。这不会得到我们期望的起始页面，但是可以给我们时间戳，这样我们就可以根据时间戳来判断是否是起始页面。

在这里，我们仅仅是将这个时间戳与所有其他潜在的起始页面时间戳进行匹配，然后我们就可以知道哪些页面属于哪些起始页面。最终产生表sessionization_step_two_origin_identification，其字段信息如下：

```
sstoi_user_id STRING
sstoi_pageview_id STRING
sstoi_origin_pageview_id STRING
```

值得一提的是，这不是识别起始页面的唯一方法。用户可以基于引入，标记出所有外部链接、主页URL或空白链入页面(表示是直接流量)作为一个起始会话。用户还可以基于动作，只测量鼠标点击后的动作。还是有很多选择方案的，但最重要的是确定什么样的会话是起始会话。

4. 对起始页面进行聚合

对于这一点，处理起来非常容易。第3步，我们将会对起始页面进行聚合，这个过程真的，真的简单。对于每个起始页面，计算其对应的页面浏览量：

```
CREATE TABLE sessionization_step_three_origin_aggregation AS

SELECT
  a.a_user_id as sstoaa_user_id,
  a.a_origin_pageview_id as sstoaa_origin_pageview_id,
  COUNT(1) as sstoaa_pageview_count
FROM
  (SELECT
    sssoo_user_id as a_user_id,
    sssoo_pageview_id as a_origin_pageview_id
  FROM
    sessionization_step_one_origins
  ) a
JOIN
```

```

(SELECT
    sstoi_user_id as b_user_id,
    sstoi_origin_pageview_id as b_origin_pageview_id
FROM
    sessionization_step_two_origin_identification
) b
ON
    a.a_user_id = b.b_user_id and
    a.a_origin_pageview_id = b.b_origin_pageview_id
GROUP BY
    a.a_user_id,
    a.a_origin_pageview_id

```

5. 按照起始页面类型进行聚合

现在是最后一步了，我们可以不必保留页面的所有的属性信息，尤其对于在前面的处理步骤之一的起始页面来说。然而，如果用户需要注意很多细节的话，那么在最后的处理阶段也是可以很容易将需要的信息添加进来的。下面是第4步：

```

CREATE TABLE sessionization_step_four_qualitative_labeling

SELECT
    a.a_user_id as ssfql_user_id,
    a.a_origin_pageview_id as ssfql_origin_pageview_id,
    b.b_timestamp as ssfql_timestamp,
    b.b_page_url as ssfql_page_url,
    b.b_referrer_url as ssfql_referrer_url,
    a.a_pageview_count as ssqfl_pageview_count
(SELECT
    ssto_a_user_id as a_user_id,
    ssto_a_origin_pageview_id as a_origin_pageview_id,
    ssto_a_pageview_count as a_pageview_count
FROM
    sessionization_step_three_origin_aggregation
) a
JOIN
(SELECT
    st_user_id as b_user_id,
    st_pageview_id as b_pageview_id,
    st_page_url as b_page_url,
    st_referrer_url as b_referrer_url,
    st_timestamp as b_timestamp
FROM
    session_test
) b
ON
    a.a_user_id = b.b_user_id and
    a.a_origin_pageview_id = b.b_pageview_id

```

6. 衡量热度

现在，使用我们的最终表，我们可以做任何我们想要做的事情。假设我们想知道会话数量、平均每个会话页面浏览量、每次会话的加权平均综合浏览量以及最大或最小浏览量。那么我们可以选择任何我们想要的标准，或根本没有任何标准。但是在这种情况下，我们通过链接URL能找到答案，其流量来源具有最好的热度。只是为了好玩，让我们也看看谁给了我们最独特的用户：

```
SELECT
  PARSE_URL(ssfql_referrer_url, 'HOST') as referrer_host,
  COUNT(1) as session_count,
  AVG(ssfql_pageview_count) as avg_pvs_per_session,
  SUM(ssfql_pageview_count)/COUNT(1) as weighted_avg_pvs_per_session,
  MAX(ssfql_pageview_count) as max_pvs_per_session,
  MIN(ssfql_pageview_count) as min_pvs_per_session,
  COUNT(DISTINCT ssfql_usr_id) as unique_users
FROM
  sessionization_step_three_origin_aggregation
GROUP BY
  PARSE_URL(ssfql_referrer_url, 'HOST') as referrer_host
```

然后我们就可以得到结果了。我们可以查看到哪个URL页面热度最大，以及确定忠实用户是哪些，等等。一旦我们拥有一个包含有这一切信息的临时表，尤其是具有一个更完整的定性属性信息的表，我们就可以回答各种各样的用户热度问题。

23.3 NASA喷气推进实验室

23.3.1 区域气候模型评价系统

——Chris A. Mattmann、Paul Zimdars、Cameron Goodale、Andrew F. Hart、

Jinwon Kim、Duane Waliser、Peter Lean共同编写

自2009年以来，我们在美国宇航局（NASA）喷气推进实验室（JPL）的团队就已经积极发展引出了一个区域气候模型评价系统（RCMES）。这个系统起先是在美国复苏和再投资法案（ARRA）资助下展开的，此系统有以下几个目标。

① 便于评价和分析区域气候模式模拟输出，其可以通过对质量受控的参考数据集的可用性的观察和对各种传感器的分析理解进行评价

和分析。这是一个有效的数据库结构，是一组用于计算度量模型评价指标和诊断的计算工具集合，而且其具有可伸缩的和友好的用户界面。

② 方便汇集大量的复杂和异构软件工具和数据访问的功能，用于展示、重组、重新格式化和可视化，这样便于将如偏差图这样的最终产品很容易地传递给最终用户。

③ 支持区域气候变化的评估，并进行影响分析，而且还需要通知决策者（如地方政府、农业部门、国家政府、水文学家等），这样他们可以做出对于大金融和社会具有重大影响的重要的决策。

④ 可以克服数据格式和元数据的异构性的问题（例如NetCDF3/4, CF元数据规范，HDF4/5, HDF-EOS元数据规范）。

⑤ 处理时空差异（如将数据进行180/80的经纬度分析，例如数据可以是一个360/360度的经纬度网格），并确保可能最初是日数据的数据，是可以和月数据进行对比的。

⑥ 支持弹性扩展，在进行区域研究时，需要特别的遥感数据和气候模型输出数据，并需要进行一系列的分析，然后就会摧毁特定的系统实例。换句话说，支持瞬态分析以及快速构建/解构RCMES实例。图23-2显示了区域气候模型评价系统的体系结构和数据流。




图23-2 JPL架构图

为实现这些目标，我们已经构建了一个多层面的系统，如图23-2所示。从左到右看下这个图，从观测采集的可用的参考数据集，特别是从卫星遥感采集的数据集，根据用于评价的气候模型所需的气候参数进入到系统。这些参数都存储在各种任务的数据集中，这些数据集被

安置在一些外部存储库中，最终送入到RCMES系统的数据库组件（RCMED：区域气候模型评价数据库）中。

举一个例子，AIRS是NASA的大气红外探测器，其可以提供很多参数，包括表面空气温度、温度和重力势；MODIS是NASA的热感成像光谱仪，其可以的提供参数包括云分数；而TRMM是NASA的热带降雨测量任务，其提供参数包括每月的降雨量。这些信息是在我们RCMES系统网站上都进行了总结，网址是<http://rcmes.jpl.nasa.gov/rcmed/param>，如图23-3所示。




图23-3 JPL物理架构图

数据集是使用Apache OODT抽取器框架加载到RCMED中的，其所需的参数，以及参数值、空间和时间约束(以及可选的高度约束)都被装

载进去了，而且还可以进行潜在的更改（如规范化，使用相同的坐标系统，从不同单位值进行换算），最终装载到一个MySQL数据库中。加载到MySQL数据库中的数据、RCMED，通过空间/时间查询和构造子集web服务公开给外部客户，具体内容就是另一个话题了。对于所有的意图和目的，其提供了和OPeNDAP同样的功能。

右边的图显示的是区域气候模型评估工具包(RCMET)。其为用户提供了能够从RCMED和其他地方产生的气候模型输出数据进行引用的能力，并可以重组这些数据，用于在时间和空间上进行匹配，并将模型数据评估的模型输出与用户选择的参考数据进行比较参考。此时，系统允许按照季节性周期合成(例如，N年的所有一月份，或所有夏季)，并为最终指标计算准备数据，也就是说，比较了模型输出值与遥感数据观测参数及其值。系统支持多种指标，如偏差计算、均方根误差(RMSE)，并生成相关的可视化图形，包括传统的饼图和为科学使用/决策支持的泰勒图。

23.3.2 我们的经验：为什么使用Hive

那么，在哪里使用Hive呢？在载入了60亿行（经度、维度、时间、数据值、高度）数据集到MySQL后，系统崩溃了，并经历过数据丢失。这可能部分是因为我们最初的策略是将所有的数据都存储到单一的一张表中了。后来，我们调整了策略通过数据集和参数进行分表，这有所帮助但也因此引入了额外的消耗，而这并非是我们愿意接受的。

相反，我们决定尝试使用Apache Hive技术。我们安装了Hive 0.5 + 20，使用CDHv3和Apache Hadoop(0 20 2 + 320)。CDHv3还包含有许多其他相关工具，包括Sqoop和Hue这些在我们的架构中都标识出来了，如图23-3底部所示。

我们使用Apache Sqoop转储数据到Hive中，然后通过写一个Apache OODT包装器，来使Hive按照空间/时间约束查询数据，然后将结果提供给RCMET和其他用户(图23-2中间部分显示)。RCMES集群的完整的架构如图23-3所示。我们有5台机器，包括图中所示的一个主/从配置，通过一个运行GigE的私人网进行连接。

23.3.3 解决这些问题我们所面临的挑战

在将数据从MySQL迁移到Hive的过程中，我们经历了在做一些简单的任务时，响应时间缓慢的问题，例如一个简单的计数DB查询(例如:hive> select count(datapoint_id) from dataPoint;)。初始化时，我们向单个表中载入了25亿条数据，并在机器配置信息中记录下来，Hive对这25亿条记录执行计数查询用了大约5~6分钟，(查询完整的68亿条记录大约需要15~17分钟)。Reduce过程也比较快(因为我们使用的是一个对于*的count操作，所以我们会经历一个reduce阶段)，但是map阶段需要消耗大部分的时间(大于占总执行时间的95%)。那个时候我们的系统由6个系统(4 x四核)组成，每台系统大约有24 GB的RAM (所有的机器如图23-3所示，再加上一个从另一个集群借来的同类型的机器)。

我们试图添加更多的节点，增加map tasktrackers(许多不同的#s)，改变DFS块大小(32MB、64MB、128 MB、256MB)，利用LZO压缩，并改变许多其他配置变量(例如io、sort.factor、io.sort.mb)，都没有有效地降低完成全局计数所需要的时间。但我们却发现一直存在一个高I/O等待节点，而无论我们执行多少任务。数据库的大小大约是200GB，而使用MySQL对25亿和67亿行数据执行计数只需要花几秒钟时间。

Hive社区成员加入到了我们公司，为我们提供了新的视角，期间HDFS读取速度提高到大约60 MB / 秒，对比本地磁盘读取速度是1 GB / 秒，这当然还取决于网络速度和namenode的负荷情况。社区成员提出的建议是，我们在Hadoop任务中大约需要16个Mapper才能和一个本地非Hadoop任务的I / O性能相当。此外，Hive社区成员建议我们通过减少每个Mapper处理的分割大小(输入大小)来增加总体Mapper的数量(也就是增加并发量)，并指出我们应该检查以下参数：

mapred.min.split.size、mapred.max.split.size、
mapred.min.split.size.per.rack和mapred.min.split.size.per.node，并建议这些参数值应设置为64 MB。最后，社区建议我们查看一个基准计算过程，也就是通过使用count(1)而不是count (datapoint_id)来计算行数，因为没有列引用意味着没有序列化和反序列化的过程，所以因为前者更快，例如，如果用户的表是RCFile格式存储的。[\(译者注：原文是后者更快，实际上后者是需要序列化和反序列化过程的。\)](#)

基于上述反馈，我们可以为RCMES的Hive集群基于一个计数基准查询进行调优，并在规定的响应时间内返回一个计数查询，最终利用上述资源，可以在15秒内从RCMET中对数十亿行数据进行空间/时间查询，这使Hive对于我们的系统架构而言，成为一个可行的和绝佳的选择。

我们已经描述了在JPL RCMES系统中使用Apache Hive的情况。我们在一个案例研究中描述了我们想要通过Hive探索云计算技术并替代MySQL，并从配置需求上使它的规模水平可以存储数百亿行数据，并有弹性地摧毁和重建存储于其中的数据。

Hive很好地满足了我们的系统需求，而我们正积极寻找更多的方法将其集成到RCMES系统中。

23.4 Photobucket

Photobucket是当前因特网上最大的专业网上相簿服务公司。其在2003年由Alex Welch 和 Darren Crystal创立，随后Photobucket很快成为互联网上最流行的网站之一，并吸引了超过一亿名用户和数十亿的存储和共享媒体。用户和系统数据分布在成百上千个MySQL实例上、成千上万个Web服务器上和PB级别的文件系统上。

23.4.1 Photobucket 公司的大数据应用情况

在2008年之前，Photobucket还没有专门的内部分析系统。业务用户提出的问题横跨数百台MySQL实例并最终在Excel中手动聚合。

在2008年，Photobucket首次开始着手实施数据仓库建设，致力于解决由一个快速增长的公司所带来的日益复杂的数据处理问题。

第一次迭代的数据仓库是一个开源的系统，包括一个Java SQL优化器和一组底层的PostgreSQL数据库。这个系统直到2009年都工作完好，但是其架构上的缺陷很快明显凸现。工作数据集迅速变得比实际可提供的内存大，再加上在PostgreSQL节点上重新对数据进行划分非常之困难，导致我们不得不对集群进行扩大。

在2009年，我们开始调查系统，使我们能够随着数据量的不断增长不断地向外扩展，使之仍然能够满足我们与业务用户签订的服务等级协议（SLA）。Hadoop迅速成为消费和分析每日由系统生成的TB级别的数据最受欢迎的工具，但是阻碍全面使用的一个负面因素就是对于简单的ad-hoc查询都要编写复杂的MapReduce程序。值得庆幸的是，Facebook几周后开源的Hive很好地破解了这个ad-hoc查询复杂的问题。

Hive相对于以前的数据仓库实现具有很多优势。

关于为什么我们选择Hadoop和Hive，这里列举了几个例子。

- ① 能够处理结构化和非结构化数据。
- ② 从Flume、Scribe或MountableHDFS中实时导数据到HDFS中。
- ③ 可以通过UDF进行功能扩展，。
- ④ 一个专门为构建OLAP与OLTP的文档充分的、类SQL的接口。

23.4.2 Hive所使用的硬件资源信息

对于数据节点使用Dell R410，4×2TB硬盘，24GB RAM；对于管理节点使用Dell R610，2×146GB（RAID 10）硬盘和24GB RAM。

23.4.3 Hive提供了什么

Photobucket公司使用Hive的主要目标是为业务功能、系统性能和用户行为提供答案。为了满足这些需求，我们每晚都要通过Flume从数百台服务器上的MySQL数据库中转储来自Web服务器和自定义格式日志TB级别的数据。这些数据有助于支持整个公司许多组织，比如行政管理、广告、客户支持、产品开发和操作，等等。对于历史数据，我们保持所有MySQL在每月的第一天创建的所有数据作为分区数据并保留30天以上的日志文件。Photobucket使用一个定制的ETL框架来将MySQL数据库中数据迁移到Hive中。使用Flume将日志文件数据写入到HDFS中并按照预定的Hive流程进行处理。

23.4.4 Hive支持的用户有哪些

行政管理依赖于使用Hadoop提供一般业务健康状况的报告。Hive允许我们解析结构化数据库数据和非结构化的点击流数据，以及业务所涉及的数据格式进行读取。

广告业务使用Hive筛选历史数据来对广告目标进行预测和定义配额。产品开发无疑是该组织中产生最大数量的特定的查询的用户了。对于任何用户群，时间间隔变化或随时间而变化。Hive是很重要的，因为它允许我们通过对在当前和历史数据中运行A / B测试来判断在一个快速变化的用户环境中新产品的相关特性。

在Photobucket公司中，为我们的用户提供一流的系统是最重要的目标。从操作的角度来看，Hive被用来汇总生成跨多个维度的数据。在公司里知道最流行的媒体、用户、参考域是非常重要的。控制费用对于任何组织都是重要的。一个用户可以快速消耗大量的系统资源，并显著增加每月的支出。Hive可以用于识别和分析出这样的恶意用户，以确定哪些是符合我们的服务条款，而哪些是不符合的。也可以使用Hive对一些操作运行A / B测试来定义新的硬件需求和生成ROI计算。Hive将用户从底层MapReduce代码解放出来的能力意味着可以在几个小时或几天内就可以获得答案，而不是之前的数周。

23.5 SimpleReach

——Eric Lubow

在SimpleReach中，我们使用Cassandra来存储我们所有的社交网络产生的原始数据。行的键的格式是一个账号ID（其也是MongoDB的ObjectId）和一个内容元素ID（被跟踪的内容元素的URL链接的MD5哈希值），这两者间使用下划线进行分割，结果集中的数据也是按照这个分隔符进行划分的。这行中的列是类似于如下展示的混合在一起的一组列：

```
4e87f81ca782f3404200000a_8c825814de0ac34bb9103e2193a5b824
=> (column=meta:published-at, value=1330979750000, timestamp= 1338919372934628)
=> (column=hour:1338876000000_digg-diggs, value=84, timestamp= 1338879756209142)
=> (column=hour:1338865200000_googleplus-total, value=12, timestamp=
1338869007737888)
```

为了能够访问这些组合列，我们需要知道列名对应的十六进制键的值。在我们的例子中，也就是我们需要执行列名(meta:'published-at')的十六进制的键值。这个十六进制键和值的形式如下：

```
00046D65746100000C7075626C69736865642D617400 =meta:published-at
```

一旦将列名转换成十六进制格式，Hive查询就可以对之进行处理了。查询语句的第一部分是LEFT SEMI JOIN，其用于模拟一个子查询SQL。后面所有的使用SUBSTR和INSTR的引用都是来处理不同情况的组合列的。因为我们已经知道“hour:”列（例如，SUBSTR(r.column_name, 10, 13)）的第10~第23个字符是时间戳，所以我们可以将其截取出来并作为返回值返回，或者用作其他对比。

INSTR用于对比列名并保证返回的结果集在输出中总是位于相同位置的相同列。作为Ruby函数的一部分的SUBSTR也用于对比。SUBSTR返回值是一个以毫秒表示的时间戳（long型的），start_date和end_date同样是这样的以毫秒表示的时间戳。这意味着传入的值可以作为列名的一部分进行匹配。

这个查询的目的是将数据从Cassandra中导出成CSV文件，最终为我们的出版商提供聚合后的数据。其是通过我们Rails栈中的一个离线处理任务完成的。具有一个完整的CSV文件意味着Hive查询中必须要包含有所有的使用到的列的列名（这意味着我们需要在没有数据的地方补上数据）。我们可以通过使用CASE语句将我们的宽行转换成固定列的表。

如下是处理CSV文件的HiveQL语句：

```
SELECT CAST(SUBSTR(r.column_name, 10, 13) AS BIGINT) AS epoch,
SPLIT(r.row_key, '_')[0] AS account_id,
SPLIT(r.row_key, '_')[1] AS id,
SUM(CAST(CASE WHEN INSTR(r.column_name, 'pageviews-total') > 0
THEN r.value ELSE '0' END AS INT)) AS pageviews,
SUM(CAST(CASE WHEN INSTR(r.column_name, 'digg-digg') > 0
THEN r.value ELSE '0' END AS INT)) AS digg,
SUM(CAST(CASE WHEN INSTR(r.column_name, 'digg-referrer') > 0
THEN r.value ELSE '0' END AS INT)) AS digg_ref,
SUM(CAST(CASE WHEN INSTR(r.column_name, 'delicious-total') > 0
THEN r.value ELSE '0' END AS INT)) AS delicious,
SUM(CAST(CASE WHEN INSTR(r.column_name, 'delicious-referrer') > 0
THEN r.value ELSE '0' END AS INT)) AS delicious_ref,
SUM(CAST(CASE WHEN INSTR(r.column_name, 'googleplus-total') > 0
THEN r.value ELSE '0' END AS INT)) AS google_plus,
SUM(CAST(CASE WHEN INSTR(r.column_name, 'googleplus-referrer') > 0
THEN r.value ELSE '0' END AS INT)) AS google_plus_ref,
SUM(CAST(CASE WHEN INSTR(r.column_name, 'facebook-total') > 0
THEN r.value ELSE '0' END AS INT)) AS fb_total,
SUM(CAST(CASE WHEN INSTR(r.column_name, 'facebook-referrer') > 0
THEN r.value ELSE '0' END AS INT)) AS fb_ref,
SUM(CAST(CASE WHEN INSTR(r.column_name, 'twitter-tweet') > 0
THEN r.value ELSE '0' END AS INT)) AS tweets,
SUM(CAST(CASE WHEN INSTR(r.column_name, 'twitter-referrer') > 0
THEN r.value ELSE '0' END AS INT)) AS twitter_ref,
SUM(CAST(CASE WHEN INSTR(r.column_name, 'linkedin-share') > 0
THEN r.value ELSE '0' END AS INT)) AS linkedin,
SUM(CAST(CASE WHEN INSTR(r.column_name, 'linkedin-referrer') > 0
THEN r.value ELSE '0' END AS INT)) AS linkedin_ref,
SUM(CAST(CASE WHEN INSTR(r.column_name, 'stumbleupon-total') > 0
THEN r.value ELSE '0' END AS INT)) AS stumble_total,
SUM(CAST(CASE WHEN INSTR(r.column_name, 'stumbleupon-referrer') > 0
THEN r.value ELSE '0' END AS INT)) AS stumble_ref,
SUM(CAST(CASE WHEN INSTR(r.column_name, 'social-actions') > 0
THEN r.value ELSE '0' END AS INT)) AS social_actions,
SUM(CAST(CASE WHEN INSTR(r.column_name, 'referrer-social') > 0
THEN r.value ELSE '0' END AS INT)) AS social_ref,
MAX(CAST(CASE WHEN INSTR(r.column_name, 'score-realtime') > 0
```

```

THEN r.value ELSE '0.0' END AS DOUBLE)) AS score_rt
FROM content_social_delta r
LEFT SEMI JOIN (SELECT row_key
FROM content
WHERE HEX(column_name) = '00046D65746100000C7075626C69736865642D617400'
AND CAST(value AS BIGINT) >= #{start_date}
AND CAST(value AS BIGINT) <= #{end_date}
) c ON c.row_key = SPLIT(r.row_key, '_')[1]
WHERE INSTR(r.column_name, 'hour') > 0
AND CAST(SUBSTR(r.column_name, 10, 13) AS BIGINT) >= #{start_date}
AND CAST(SUBSTR(r.column_name, 10, 13) AS BIGINT) <= #{end_date}
GROUP BY CAST(SUBSTR(r.column_name, 10, 13) AS BIGINT),
SPLIT(r.row_key, '_')[0],
SPLIT(r.row_key, '_')[1]

```

这个查询的输出是以逗号分隔的文件（CSV文件），内容如下面例子所示（为清晰展示对输出中一些行进行了转行并增加了空行进行分隔）：

```

epoch,account_id,id,pageviews,digg,digg_ref,delicious,delicious_ref,
google_plus,google_plus_ref,fb_total,fb_ref,tweets,twitter_ref,
linkedin,linkedin_ref,stumble_total,stumble_ref,social_actions,social_ref,score_rt
1337212800000,4eb331eea782f32acc000002,eaff81bd10a527f589f45c186662230e,
39,0,0,0,0,0,0,2,0,20,0,0,0,0,0,22,0
1337212800000,4f63ae61a782f327ce000007,940fd3e9d794b80012d3c7913b837dff,
101,0,0,0,0,0,44,63,11,16,0,0,0,55,79,69.64308064
1337212800000,4f6baedda782f325f4000010,e70f7d432ad252be439bc9cf1925ad7c,
260,0,0,0,0,0,8,25,15,34,0,0,0,23,59,57.23718477
1337216400000,4eb331eea782f32acc000002,eaff81bd10a527f589f45c186662230e,
280,0,0,0,0,0,37,162,23,15,0,0,2,56,179,72.45877173
1337216400000,4ebd76f7a782f30c9b000014,fb8935034e7d365e88dd5be1ed44b6dd,
11,0,0,0,0,0,1,1,4,0,0,0,0,5,29.74849901

```

23.6 Experiences and Needs from the Customer Trenches

标题：来自Karmasphere的视角

——Nanda Vijaydev

23.6.1 介绍

在超过18个月的时间里，Karmasphere一直忙于越来越多的使用Hadoop的公司，这些公司都转向使用Hive作为分析师团队和业务团队提供服务的最优方式。本章的第一部分说明了我们在客户环境中不断反复使用Hive进行分析的一些实际场景的使用技术。

我们所涵盖的使用场景例子如下。

- ① 为Hive提供最优数据格式化类型。
- ② 分区和性能。
- ③ 使用Hive函数（包括正则、Explode函数和连词）进行文本分析。

随着我们一直合作的公司计划并生产中使用Hive，他们一直在寻找一些增强功能，使基于Hive获取Hadoop更容易使用、更富有成效、更强大，而且可以让他们的组织中更多的人进行使用。

当他们将Hadoop和Hive加入到他们现有的数据架构中后，他们还想让从Hive查询的结果系统化、可以进行共享并可以集成到其他数据存储、电子表格、BI工具和报告系统中。

特别地，这些公司有如下要求。

- ① 获取数据，检测原始格式，并创建元数据的便捷方法。
- ② 在一个集成的、多用户环境下协同工作。
- ③ 探索和迭代分析数据。
- ④ 可保存和重用路径。
- ⑤ 对数据、表和列的安全的细粒度控制，并区分访问不同的业务线数据。
- ⑥ 业务用户不需要SQL技能就可访问并进行分析。
- ⑦ 调度查询，并将生成的结果自动导出到非Hadoop的数据存储中。

⑧ 与Microsoft Excel、Tableau、Spotfire以及其他电子表格、报告系统、仪表板、BI工具进行集成。

⑨ 可以管理基于Hive的功能，包括进行查询、结果输出、可视化以及Hive的标准组件，如UDF和SerDe。

23.6.2 Customer Trenches的用例

1. Customer trenches #1: 为Hive优化存储格式

许多Hive用户反复反馈的一个问题就是Hive中的数据使用什么存储格式进行存储以及如何使用这些数据。

Hive本身内置可以支持许多种数据格式，但有一些自定义的专有格式就不支持了。有一些数据格式支持为用户解决如何从一个行数据中提取出独立的部份。有时候，写一个标准的HiveSerDe来支持一个自定义的数据格式是最优方法。而在其他情况下，使用现有的Hive分隔符和Hive UDF可能是最方便的解决方案。我们合作地使用Hadoop来提供个性化服务，并使用Hive对多个输入数据流进行分析。公司的一个有代表性的案例就是：他们收到的是来自他们的一个日志数据提供者的格式，而这种格式不能轻易地分裂成列。他们试图想出一个办法使得无需编写一个自定义SerDe就可以解析数据并运行查询。

数据包含顶层的头信息和底层的多个详细信息。详细信息部分是一个嵌套在顶级对象中的JSON对象，类似于如下这样的数据集：

```
{ "top" : [
  {"table":"user",
   "data":{
     "name":"John Doe", "userid":"2036586", "age":"74", "code":"297994", "status":1},
   {"table":"user",
    "data":{
      "name":"Mary Ann", "userid":"14294734", "age":"64", "code":"142798",
      "status":1},
   {"table":"user",
    "data":{
      "name":"Carl Smith", "userid":"13998600", "age":"36", "code":"32866",
      "status":1},
   {"table":"user",
    "data":{
      "name":"Anil Kumar", "userid":"2614012", "age":"69", "code":"208672", "status":1},
   {"table":"user",
    "data":{
      "name":"Kim Lee", "userid":"10471190", "age":"53", "code":"79365", "status":1}
  ]}
```

与客户交谈后，我们意识到他们感兴趣的是上面的示例中“data”标签下的详细字段信息。

为帮助他们解决这个问题，我们使用Hive中自带的函数get_json_object，使用方法如下。

第一步是创建一个表，其使用的是样本数据：

```
CREATE TABLE user (line string)
ROW FORMAT DELIMITED FIELDS TERMINATED BY '\n'
STORED AS TEXTFILE
LOCATION 'hdfs://hostname/user/uname/tablefolder/'
```

然后使用Hive等功能得到JSON对象，我们可以得到的嵌套JSON元素并使用UDF对其进行解析：

```
SELECT get_json_object(col0, '$.name') as name, get_json_object(col0, '$.userid') as
uid,
get_json_object(col0, '$.age') as age, get_json_object(col0, '$.code') as code,
get_json_object(col0, '$.status') as status
FROM
(SELECT get_json_object(user.line, '$.data') as col0
FROM user
WHERE get_json_object(user.line, '$.data') is not null) temp;
```

查询详细信息如下。

a. 在内部查询中提取以‘data’作为标识嵌套的JSON对象，并将其取别名为col0。

b. 然后将JSON对象分成适当的列并使用它们的标记名作为对应的列别名。

查询结果如下，这是一个CSV文件，其中第一行是字段名称：

```
"name", "uid", "age", "code", "status"
"John Doe", "2036586", "74", "297994", "1"
"Mary Ann", "14294734", "64", "142798", "1"
"Carl Smith", "13998600", "36", "32866", "1"
"Kim Lee", "10471190", "53", "79365", "1"
```

2. Customer trenches #2: 分区和性能

使用分区来保存通过数据流或定期添加到Hadoop的数据是一个最近我们看到多次的用例，而这是一个利用Hadoop和Hive来分析各种快速添加进来的数据集强大而非常有价值的方式。Web、应用、产品和传感器日志这些数据，只是Hive用户经常需要ad-hoc、重复执行和预定查询的数据。

Hive分区在正确设置后，可以允许用户查询仅在特定的分区下的数据，从而将极大地提高性能。当为表建立分区时，文件应该位于类似如下例子中给出的目录下：

```
hdfs://user/uname/folder/"yr"=2012/"mon"=01/"day"=01/file1, file2, file3  
    /"yr"=2012/"mon"=01/"day"=02/file4, file5  
    .....  
    /"yr"=2012/"mon"=05/"day"=30/file100, file101
```

通过上述目录结构，我们可以看到表可以设置年、月和日来设置分区。查询的时候可以使用yr、mon、和day作为过滤字段，同时也可 以限制在特定的查询时间访问特定的值下面的数据。我们可以观察下路径中文件夹的名称，分区的文件夹名称都是如yr=、mon=和day=这样的标识的。

在和一个高科技公司合作时，我们发现他们的文件夹没有这个明确的分区命名，而且他们不能改变他们现有的目录结构。但他们仍然希望受益于分区。他们的样品目录结构如下所示：

```
hdfs://user/uname/folder/2012/01/01/file1, file2, file3  
    /2012/01/02/file4, file5  
    .....  
    /2012/05/30/file100, file101
```

在这种情况下，我们仍然可以通过使用ALTER table语句显式地添加分区并为表添加绝对路径位置。一个简单的外部脚本可以读取目录并为ALTER TABLE语句中添加yr=、mon=、day=这样的信息并提供对应的有效的具体的文件夹名称(如yr=2012, mon=01, ...)。脚本的输出是一组使用具体的目录结构的Hive SQL语句，而且保存在一个简单的文本文件中。

```
ALTER TABLE tablename  
ADD PARTITION (yr=2012, mon=01, day=01) location '/user/uname/folder/ 2012/01/01/';  
  
ALTER TABLE tablename  
ADD PARTITION (yr=2012, mon=01, day=02) location '/user/uname/folder/ 2012/01/02/';  
...
```

```
ALTER TABLE tablename
ADD PARTITION (yr=2012, mon=05, day=30) location '/user/username/folder/ 2012/05/30/';
```

当在Hive中执行这些语句时，指定的目录下的数据就会出现在使用ALTER TABLE语句创建并定义的逻辑分区中。



提示

用户应该确保表是通过PARTITIONED BY语句为年、月和日创建分区字段的。

3. Customer trenches #3: 使用 Regex、Lateral View Explode、Ngram 和其他一些 UDF 进行文本分析

许多与我们合作的公司都有文本分析的场景，包括简单到复杂的情况。理解和使用Hive regex函数、范式和其他字符串处理函数可以解决大量的此类使用场景。

一个与我们合作的大型制造业客户有很多机器生成压缩文本数据存储到了Hadoop中。这个数据的格式如下。

- ① 每个文件中具有多行数据，而一个按照时间分区的数据桶内包含有许多这样的文件。
- ② 每一行数据都有许多按照/ r / n （回车和换行）进行划分的列。
- ③ 每列数据的形式是一个“名称： 值”对。

用例的要求如下。

- ① 读取每一行数据并将每列转换成“名称-值”对。
- ② 在特定的列中，进行词频统计和单词模式分析来分析关键词和特定的消息内容。

下面的示例展示了这个客户的样本数据资料（其中省略了一些文本内容）：

```
name:Mercury\r\ndescription:Mercury is the god of commerce, ...\\r\\ntype: Rocky\nplanet\nname:Venus\r\ndescription:Venus is the goddess of love...\\r\\ntype:Rocky planet\nname:Earch\r\ndescription:Earth is the only planet ...\\r\\ntype:Rocky planet\nname:Mars\r\ndescription: Mars is the god of war...\\r\\ntype:Rocky planet\nname:Jupiter\r\ndescription:Jupiter is the King of the Gods...\\r\\ntype: Gas planet\nname:Saturn\r\ndescription:Saturn is the god of agriculture...\\r\\ntype: Gas planet\nname:Uranus\r\ndescription:Uranus is the God of the Heavens...\\r\\ntype: Gas planet\nname:Neptune\r\ndescription:Neptune was the god of the Sea...\\r\\ntype:Gas planet
```

数据具有如下几方面特点。

- ① 行星的名字和他们的包含类型的描述信息。
- ② 每一行的数据是由一个分隔符分隔。
- ③ 在每一行有3个部分，包括“名称”、“描述”和“类型”，按照/ r / n 进行字段划分。
- ④ 其中“描述”是一个大的文本内容。

第一步是使用此示例数据创建初始表:

```
CREATE TABLE planets (col0 string)\nROW FORMAT DELIMITED FIELDS TERMINATED BY '\\n'\nSTORED AS TEXTFILE\nLOCATION 'hdfs://hostname/user/username/planets/'
```

接下来，我们运行一系列的查询，从一个使用了函数的简单的查询开始。需要注意的是用几种不同的方式编写的查询来满足相同的需求。如下查询语句的目的是演示Hive对文本解析一些关键功能。

首先，我们使用一个split函数来将数据划分的不同列保存到数组中:

```
SELECT split(col0, '(\\\\\\r\\\\\\n)') AS splits FROM planets;
```

接下来，我们LATERAL VIEW EXPLODE 函数来将划分（也就是这个数组）进行展开。这个查询的结果将是每行都是一个“名称-值”对。我们只选择那些以‘desc’开头的行。LTRIM这个函数是用来去除左端的空白字符的。

```
SELECT ltrim(splits) AS pairs FROM planets\nLATERAL VIEW EXPLODE(split(col0, '(\\\\\\r\\\\\\n)')) col0 AS splits
```

```
WHERE ltrim(splits) LIKE 'desc%'
```

现在我们描述的信息转换成了“名称-值”对，并选择有值的数据。这可以以不同的方式完成的。我们使用根据“:”进行分割并选择“值”那部分数据：

```
SELECT (split(pairs, ':'))[1] AS txtval FROM (
  SELECT ltrim(splits) AS pairs FROM planets
  LATERAL VIEW EXPLODE(split(col0, '\\\\r\\\\n')) col0 AS splits
  WHERE ltrim(splits) LIKE 'desc%')tmp1;
```

需要注意的是对于内部查询我们使用了临时标识符tmp1。当用户使用子查询的输出作为外层查询的输入时，使用别名是必须的。步骤3处理后，我们获取到“描述”中每一行的“值”部分的数据。

在接下来的步骤中，我们使用ngrams函数来显示行星描述名称前10双字母组名单词。用户也可以使用如context_ngram、find_in_set、regex_replace和其他各种各样的基于文本分析的函数：

```
SELECT ngrams(sentences(lower(txtval)), 2, 10) AS bigrams FROM (
  SELECT (split(pairs, ':'))[1] AS txtval FROM (
    SELECT ltrim(splits) AS pairs FROM planets
    LATERAL VIEW EXPLODE(split(col0, '\\\\r\\\\n')) col0 AS splits
    WHERE ltrim(splits) LIKE 'desc%') tmp1) tmp2;
```

需要注意的是，我们已经使用了像lower这样的函数来将大写字母全部转换成小写，以及使用sentences函数将文本中内容分割成单词。

关于Hive中文本分析函数的更多信息，可以参考第3章中列举的函数。

生产环境下的Apache Hive：快速增长的需求和能力。

Hive会保持继续成长，正如前面所定义的使用场景所展示的。在不同行业和不同规模的公司都将在Hadoop环境中使用Hive而受益无穷。一个强大和积极的贡献者社区，以及由Hadoop领先供应商提供的重大的研发投入，都将确保Hive已经是Hadoop之上的基于SQL的标准了，它将会成为利用Hadoop为大数据分析的标准组织中基于SQL处理的标准。

随着公司投入大量资源和时间来理解和构建Hive资源，在很多情况下，我们发现他们寻找额外的能力，使他们能够建立在他们的初始

使用Hive的基础之上，并达到更快的扩展、在他们的组织内更广泛的应用。从处理这些客户希望Hive进化到到下一个级别的需求中，有一套共同的需求已经出现了。这些需求包括如下几方面。

① 多用户环境协作。Hadoop提供了相对于传统的RDBMS的新的分析类别，在计算能力和成本上都具有优势。使用Hadoop，组织机构可以将数据和人进行分离，可以在他们可获取的每个字节的数据上执行分析，这些都通过一种方式，可以使他们能够与其他个体、团队、组织和系统分享他们的查询结果和见解。这个模型意味着为用户提供深入理解需要合作发现这些不同的数据集，再分享见解和整个组织中基于Hive分析的可用性。

② 增强生产力。Hive的当前的实现提供了一个在Hadoop之上的系列批处理环境。这意味着，一旦用户向Hadoop集群中提交一个查询作业，他们必须等待查询完成之后才能向集群提交并执行另一个查询。这可以限制用户的生产力。企业采用Hive的一个主要原因是，它使他们的SQL技术数据专业人员可以更快和更容易使用Hadoop。这些用户通常熟悉SQL编辑工具和BI产品。他们正在寻找类似的生产力环境例如增强语法高亮、代码自动完成。

③ Hive资产管理。麦肯锡近期的一份报告通过他们的数据预测了缺乏熟练的工人，可以显著降低使组织牟利。像Hive这样的技术通过允许人们在Hadoop可以用SQL技能进行分析来解决技能短缺问题。然而，组织意识到仅仅让他们的用户使用Hive是不够的。他们需要能够管理Hive资产，如查询语句（包含历史操作和版本信息）、众多的UDF、SerDe等，可以在以后进行分享和重用。组织想要构建这个Hive资产的知识存储库，而且用户可以很容易搜索到。

④ 为先进的分析技术对Hive进行扩展。许多公司正在寻找在Hadoop中重建他们在传统的RDBMS中分析的系统。虽然并不是SQL环境的所有功能都很容易转化为Hive函数，其中一些是因为数据存储的固有局限性，有一些高级分析功能（像RANK，等等），这些Hadoop是可以进行处理的。此外，组织使用传统工具如SAS和SPSS花了巨大的资源和时间在构建分析模型上，并希望能够在Hadoop通过Hive查询更好地使用这些模型。

⑤ SQL技能外扩展Hive。因为Hadoop在组织中积蓄了大量优势，并成为一个IT基础设施之上的关键的数据处理和分析架构，这在具有

不同的技能和能力的用户当中很流行。尽管Hive很容易适应具有SQL技能的用户，其他的懂得SQL并不多的用户也在寻求可以在基于Hadoop的Hive上像在传统的BI工具中通过拖拖拽拽就可以执行分析的功能。能够在Hive之上支持交互式表单，能够通过简单的基于Web的形式提示用户提供的列值是一种常见的功能。

⑥ 数据探索能力。传统的数据库技术提供数据浏览功能。例如，一个用户可以查看一个整数列的最小值，最大值。此外，用户还可以通过可视化的方式查看这些列，在他们执行分析数据之前理解数据分布。因为Hadoop存储了数百TB的数据，并且通常是PB级别的，对于特定的使用场景，顾客需要类似的功能。


⑦ 调度和操作Hive查询。当公司使用具有Hadoop的Hive发现了一些深刻见解时，他们也在寻求实施这些见解和安排在一个正则区间运行这些查询。虽然目前已经有了可用的开源替代方案，但当公司也想管理Hive查询的输出时就会功亏一篑。例如，将结果集转移到一个传统的RDBMS系统或BI堆栈。管理特定的用例，公司通常必须手工串起各种不同的开源工具或依靠可怜的JDBC连接器进行执行。

⑧ 关于Karmasphere。Karmasphere是一家软件公司，位于加州硅谷，专注于帮助分析师团队和业务用户使用Hadoop的大数据分析能力。他们的旗舰产品，Karmasphere 2.0，是基于Apache Hive的，并扩展实现了多用户图形化工作空间。

- a. 重用标准的Hive表、SerDe和UDF。
- b. 为分析师团队和业务用户提供社交化的、基于项目的大数据分析服务。
- c. 可以方便和其他集群进行数据整合。
- d. 基于启发式的识别和提供多种流行的数据存储格式来创建表。
- e. 可视化的和迭代式的数据探索和分析。
- f. 图形化的对基于Hive的数据集进行分析探索。
- g. 可以共享和调度查询以及结果，并提供可视化操作和展示。

h. 和传统表格、报表、仪表盘、BI工具很容易进行集成整合。

图23-4展示了Karmasphere 2.0的基于Hive的大数据分析环境的操作界面截图。



My Analytics Workspace : user: Gil Allouche

My Recent Activity

- Product Use Saved query Machine and device event log. 06/04/12 13:58:11
- Product Error Logs & Support Saved visualization Geo Location Analysis. 06/03/12 07:33:25
- Product Use Saved result set Device usage by Geo location. 06/02/12 20:52:59
- R&D Feedback Saved visualization Clickstream analysis. 05/31/12 19:34:28
- Product Error Logs & Support Saved visualization Social media data and CRM application analysis. 05/02/12 22:10:45
- R&D Feedback Saved visualization Demographic Analysis. 05/25/12 02:45:23
- R&D Feedback Saved query Cross-device game usage data. 05/22/12 08:56:34
- Product Error Logs & Support Saved resultset Call home machine logs by error type. 05/27/12 18:09:11

My Projects

- Products Use Analyze the different usage patterns of the product. 06/01/12 13:58:11
- Product Error Logs & Support Correlation analysis of CRM data and product error logs. 05/21/12 9:08:08
- R&D Feedback Streamline product and device logs to improve R&D Process and reduce peaks. 05/29/12 15:32:24

Recent Activity

- Nanda saved resultset ...
- Martin Hall saved quer...
- Cos published query to...
- Manish saved query cu...
- Rich Guth scheduled q...
- Gil saved resultset web...
- Elise saved visualizatio...
- Mike saved resultset pr...
- Abe saved query defect...
- Neena saved resultset ...
- Tom saved visualizatio...
- Rich saved resultset ti...
- Manish saved query re...
- Nanda saved query de...
- Abe saved resultset def...
- Martin shared visualiz...
- Tom scheduled query c...
- Elise shared query soci...

My Results

- Product Use Patterns Popular product use paths. 06/02/12 10:17:19
- High Priority Bugs Device logs, Product logs & CRM data. 05/29/12 9:55:23
- Bug Report by Customer Priority Bugs from top 50 revenue accts. 05/26/12 15:39:02

www.karmasphere.com © 2012 Karmasphere Inc., All Rights Reserved

图23-4 Karmasphere 2.0的屏幕截图

⑨ Hive特性调查。对于这些需求我们期望能得到反馈并最终能在快速发展的Hive社区中进行分享。如果你有兴趣看看别人的想法的话，那么请访问如下链接：<http://karmasphere.com/hive-features-survey.html>。

[1]<http://www.r-bloggers.com/taking-r-to-the-limit-large-datasets-predictive-modeling-with-pmml-and-adapa/>。

[2]关于广义相加模型（GAM）的更多细节信息请参考Hastie等人在2001年发布的用于分析的GAM实现的R包，这个神奇的包可以通过如

下链接进行下载: <http://cran.r-project.org/>。

术语词汇表

亚马逊弹性MapReduce (EMR)

亚马逊的EMR是基于亚马逊EC2（弹性计算云）的托管Hadoop服务。

Avro

Avro是一个新的序列化格式，其用于解决一些其他序列化格式演变过程中发现的常见问题。使用它的一些好处是其具有丰富的数据结构、快速的二进制格式，支持远程过程调用，而且内置模式演化。

Bash

Bash是Linux和Mac OS X系统的默认命令行交互shell。

S3中的数据桶

数据桶是使用S3时用户可以具有和管理的最顶层容器的术语。一个用户可以具有很多的数据桶，其类似于物理硬盘的root根目录。

命令行交互界面 (CLI)

命令行交互界面（也就是CLI）是指可以执行Hive语句“脚本”并和用户输入信息进行交互的命令行界面。

数据仓库

数据仓库指用于报告、趋势等分析的一组结构化数据组成的库。数据仓库可以提供数据批处理，是离线的，而不是像电子商务这样提供实时响应能力的系统。

Derby

Derby是一个轻量级的SQL数据库，其可以嵌入到Java应用程序中。其运行在相同的进程中并将数据存储到本地文件中。Hive元数据存储中默认使用Derby作为元数据库。可以访问<http://db.apache.org/derby/>获得更多信息。

动态分区

动态分区是HiveQL对于SQL一个扩展。使用动态分区可以允许用户将查询结果插入到表分区中，而分区字段是一个或者多个不同的分区列值，具体的分区值将由查询结果动态地生成。使用动态分区可以非常方便地将查询结果写入到新表的大量分区中，而无需为每个分区列值都写一个单独的查询语句。

Ephemeral Storage 临时性存储

对于虚拟亚马逊EC2集群的节点，节点上的硬盘存储空间就被称为临时性存储。这是因为和普通的物理存储集群不同，当这类集群关闭后这些存储数据就会被清除掉。因此，当使用EC2集群，例如亚马逊弹性MapReduce集群时，要注意将重要的数据备份到S3上。

外部表

外部表指使用不在Hive控制范围内的存储路径和内容的表。使用外部表会比较方便将数据和其他工具共享，但是需要其他的处理过程来管理数据的生命周期。也就是说，当创建了一个外部表时，Hive并没有创建这个外部存储路径（对于分区表的话还应包括分区路径文件夹），同样地，当删除外部表后，并不会删除外部路径下的数据。

Hadoop分布式文件系统（HDFS）

Hadoop分布式文件系统（HDFS）是一个用于数据存储的分布式的、弹性的文件系统。HDFS被优化为可以快速扫描硬盘上大的连续的数据块。集群中的分布式提供了数据存储的横向扩展。HDFS文件的数据块在集群内会被复制成多份（默认情况下是3份）来防止当磁盘坏掉或者整个服务器坏掉时的数据丢失。

HBase

HBase是使用**HDFS**作为持久化存储表数据的**NoSQL**数据库。
HBase是列式的键-值对存储的设计，用于提供传统的快速响应查询和行级别的数据更新和插入。列式存储意味着磁盘上的数据存储是按照多组列够成的，也就是列族，而不是按照行来组织的。这个特性使得可以快速查询列的子集数据。键-值对存储意味着行是按照一个唯一键和整行所对应的值来获取的。**HBase**并没有提供一种**SQL**方言，但是可以使用**Hive**来查询**HBase**表。

Hive

Hive是一个数据仓库工具。**Hive**对存储在**HDFS**、**HBase**表或者其他存储上的数据进行了抽象，形成了表。**Hive**查询语言（**HQL**）是结构化查询语言（**SQL**）的方言。

Hive查询语言（**HQL**）

Hive查询语言（**HQL**）是**Hive**自己的结构化查询语言（**SQL**）的一种方言。通常缩写为**HiveQL**或者**HQL**。

输入文件格式（**Input Format**）

输入文件格式决定了输入数据流（通常是来自于文件的）是如何分割成记录的。**SerDe**用于将记录分割成列。用户自定义的输入文件格式可以在创建表时通过**INPUTFORMAT**语句来进行指定。默认的输入文件格式也就是默认的**STORED AS TEXTFILE**语句实际是就是**org.apache.hadoop.mapreduce.lib.input.TextInputFormat**的简写形式。输出文件格式（**Output Format**）是类似的。

JDBC

Java数据库连接API（**JDBC**）提供了使用**Java**代码访问包括**Hive**的**SQL**系统的接口。

Job任务

在**Hadoop**上下文中，一个**Job**就是一个提交给**MapReduce**的独立的工作流。其中包含有需要执行一个完整的计算，从读取输入到生成输出。

出的完整过程。*MapReduce* 框架中的*JobTracker*会将其分解成一个或者多个可以在集群中分布式执行的*task*任务。

JobTracker

*JobTracker*是使用*Hadoop*的*MapReduce*的所有任务（Job）的最顶层控制器。*JobTracker*接收提交上来的Job，决定执行什么task以及分发到哪里去执行，监控他们的执行过程，并且在需要的时候重跑失败的task，其还提供了一个网页控制台界面用户监控Job和task的执行过程，查看执行日志，等等。

任务流（Job Flow）

任务流是亚马逊弹性*MapReduce*（EMR）中使用到的一个术语，其表示在一个为特定目的而创建的临时EMR集群上执行的一系列连续的*job*任务。

JSON

JSON 即 JavaScript Object Notation，它是一种轻量级的数据交换格式，非常适合于服务器与 JavaScript 的交互，因此常用于网络应用程序。

Map阶段

Map阶段是指*MapReduce*处理过程中进行Map操作的那个阶段，在这个阶段输入的键-值对集合会转换成一个新的键-值对集。对于每个输入键-值对，可以产生零到多个输出键-值对。输入和输出键以及输入和输出值可能是完全不同的。

MapR

MapR是一个商业版本的*Hadoop*，*MapR*文件系统（MapR-FS）代替了*HDFS*。MapR-FS是一个高性能的分布式文件系统。

MapReduce

*MapReduce*是Google提出的一个软件架构，用于大规模数据集的并行运算。其将计算过程分为两个过程映射（Map）过程和化简

（Reduce）过程，map过程用来把一组键-值对映射成一组新的键-值对，并通过指定并发的Reduce过程，来保证所有映射的键-值对中的每一个共享相同的键组。MapReduce通过把对数据集的大规模操作分发给网络上的每个节点实现可靠性。每个节点会周期性的把完成的工作和状态的更新报告回来。如果一个节点保持沉默超过一个预设的时间间隔，主节点（类同Google档案系统中的主服务器）记录下这个节点状态为死亡，并把分配给这个节点的数据发到别的节点。每个操作使用命名文件的不可分割操作以确保不会发生并行线程间的冲突。当文件被改名的时候，系统可能会把他们复制到任务名以外的另一个名字上去。

元数据存储（Metastore）

元数据存储是指存储如表结构信息这样的“元数据”信息的服务。Hive需要使用元数据存储服务才能够使用。默认情况下，Hive使用的元数据存储是内置的Derby SQL Server服务，其提供了有限的，单进程的SQL支持。生产环境下需要使用像MySQL这样的提供全功能的关系型数据库作为元数据存储。

NoSQL

NoSQL指的是非关系型数据库，不支持关系型模型的数据管理、结构化查询语言、以及传统的update操作。这些数据存储将这些功能剔除掉了，目的是为大数据处理提供更具成本效益的可伸缩性、高可用性，等等。

ODBC

ODBC全称是开放数据库连接API，其为其他应用程序提供了访问SQL系统的接口，当然包括访问Hive的接口。通过来说Java应用程序是使用JDBC API进行连接的。

输出文件格式（Output Format）

输出文件格式（OutputFormat）决定了记录是如何写入到输出流中的，通常是如何写入到文件中的。一个SerDe处理了如何将每行记录序列化成合适的字节流的问题。可以在创建表语句中通过OUTPUTFORMAT语句执行用户自定义的文件输出格式。默认的输出

格式是STORED AS TEXTFILE， 其是org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat的简化形式。相关的可查看下输入文件格式（InputFormat）。

分区

分区是表数据的一个子集，同一个分区下的分区字段内容是相同的。在Hive中，和大多数支持数据分区的数据库一样，每个分区都对应着不同的物理存储路径（在Hive中就是表路径下的子文件夹）。使用分区有几个好处。分区字段的值在分区数据中其实是没有的，这样就可以节约存储空间，同时对于使用WHERE语句的查询来说通过限制特定的分区字段可以减少输入的数据量而提高执行效率，因为这样可以避免全表扫描。同样可以参考下动态分区。

Reduce

Reduce过程是MapReduce处理过程的一部分，在这个过程里来自map阶段的键-值对会被进行处理。MapReduce的一个重大的特性就是来自所有map task产生的键-值对，具有相同键的值会被分发到同一个reduce task中，因此值的集合可以根据实际情况进行“化简”。例如，一组整数可以进行相加或者求平均计算，而一组字符串可以进行去重处理，等等。

关系模型

关系模型是数据库管理系统的最常见的模型，其是基于数据组织和数据操作的逻辑模型。数据结构的声明以及如何操作数据都是由用户定义的，最常见就是使用结构化查询语言（SQL）。而相应的具体实现会将这些声明转换成存储、获取和操作数据等处理过程。

S3

S3上亚马逊网络服务（AWS）的分布式文件系统。在运行MapReduce任务时可以和HDFS结合使用或者替代HDFS进行使用。

SerDe

序列化器/反序列化器或简写为SerDe，用于将记录的字解析成列或字段，也就是反序列化过程。它也用来创建这些记录字节(也就是序列化过程)。相反，输入格式（InputFormat）用于将一个输入流转换为记录而输出格式（OutputFormat）用来将记录写到一个输出流。在创建Hive表时可以指定SerDe。默认的SerDe支持在第3.3节“文本文件数据编码”中所介绍的字段分隔符，讨以及各种优化如简易解析。

结构化查询语言（SQL）

结构化查询语言（SQL）是一种实现了关系模型查询和操纵数据的语言。缩写为SQL。对于SQL虽然有一个经历了很多次修改的ANSI标准，但是所有的SQL方言都可以广泛地添加使用自定义扩展和改变。

Task

在*MapReduce*上下文中，*task*是在单个集群节点上工作的最小单元，其作为整个*job*的一个处理单元。默认情况下，每个*task*都会启动单独的一个JVM进程。每个*map*和*reduce*调用都有其自身的*task*。

Thrift

Thrift是Facebook发明的RPC系统，其被集成到了Hive中。远程进程可以通过Thrift发送Hive语法到Hive中。

用户自定义聚合函数（UDAF）

用户自定义聚合函数（UDAF）是指输入为多行（或多行的多个字段）而产生唯一一个“聚合的”结果数据的用户自定义函数，例如求输入数据的行数，计算一组值的和或平均值，等等。这个术语简称UDAF。请参考第13章“用户自定义函数”和第13.9节“用户自定义聚合函数”。

用户自定义函数（UDF）

用户自定义函数（UDF）是指Hive用户用于扩展其处理操作所实现的函数。有时这个术语也包含Hive内置的函数，其也通常表示那些一条输入行（或一行数据中某个列）并产生一条输出（例如，并不会

改变输出记录的行数) 的函数。关于UDF的更多信息, 请参考第13.9节“用户自定义聚合函数”和第13.10节“用户自定义表生成函数”。

用户自定义表生成函数 (UDTF)

用户自定义表生成函数 (UDTF) 是指可以将每条记录的一个字段的值转换生成多行记录的用户自定义函数。例子如`explode`函数, 这个函数可以将一个数组字段的值转换成多行, 而且对于Hive v0.8.0和更高版本, 可以将`map`类型的字段转换成键和值的多行数据。关于UDTF的详细信息, 请参考第13章“用户自定义函数”和第13.9节“用户自定义聚合函数”。

书末说明

《Hive编程指南》书封面上的生物是一只黄边胡蜂（胡蜂属的），还有它的蜂巢。黄边胡蜂是南美的唯一的一种胡蜂，其是在欧洲移民时带到美洲的。这种胡蜂可以在整个欧洲以及亚洲大部分地区找到，其可以根据不同气候按照需要通过不同的蜂巢建造技术来进行适应。

胡蜂是一种社会性昆虫，和蜜蜂、蚂蚁是一样的。胡蜂的蜂巢里有一个蜂后，以及少量的雄性胡蜂，而大部分都是雌性的工蜂。雄蜂的使命就是和蜂后进行繁殖，其后不久它们就会死去。而雌性工蜂的作用就是建造蜂巢，搬运食物，以及照顾蜂后的卵。

胡蜂的巢和本书是一致的，因为蜂巢是由木浆形成的多层六角形格子构成的。最终形成的结果就是一个附着在短杆上的梨型巢。在寒冷地区，冬天的时候胡蜂会放弃蜂巢而转移到空的树干里甚至是人类的房屋里，蜂后和蜂卵会一直待到天气变暖为止。蜂卵孵化出新的胡蜂然后形成新的殖民地，而蜂巢会进行再次构造。本书的封面图片来自于Johnson的《博物学》。

欢迎来到异步社区！

异步社区的来历

异步社区(www.epubit.com.cn)是人民邮电出版社旗下IT专业图书旗舰社区，于2015年8月上线运营。

异步社区依托于人民邮电出版社20余年的IT专业优质出版资源和编辑策划团队，打造传统出版与电子出版和自出版结合、纸质书与电子书结合、传统印刷与POD按需印刷结合的出版平台，提供最新技术资讯，为作者和读者打造交流互动的平台。



The screenshot shows the homepage of the Epubit website. At the top, there is a navigation bar with the logo '异步社区' (Epubit), '技术圈', '图书', '电子书', '文章', a search bar, and user icons for login and writing. The main banner features the text '我们岁岁拉' (We are here every year) over a colorful sunset background. Below the banner, a large text '异步社区成立一周年大型活动开启' (The first anniversary of the Async Community has started) is displayed, along with a promotional message for a year-end discount: '周年庆满减促销 | 满100元减20元、满150元减35元、满200元减50元'. The page is filled with book covers for various titles, including 'CCIE路由和交换认证考试指南 (第5版) (第1卷)', '数据科学实战手册 (R+Python)', '软技能：代码之外的生存指南', 'Python密码学编程', 'Python游戏编程快速上手', '机器学习项目开发实战', '树莓派Python编程入门与实战 (第2版)', and '像计算机科学家一样思考Python (第2版)'. On the right side, there is a sidebar for '近期活动' (Recent Activities) showing posts like '异步社区成立一周年大型赠书活动开启!' and '2016 iWeb峰会北京站即将开启，为HTML5呐喊！', and a section for '每周半价电子书' (Half-price e-books every week) featuring '树莓派Python编程入门与实战 (第2版)'.

社区里都有什么？

购买图书

我们出版的图书涵盖主流IT技术，在编程语言、Web技术、数据科学等领域有众多经典畅销图书。社区现已上线图书1000余种，电子书400多种，部分新书实现纸书、电子书同步出版。我们还会定期发布新书书讯。

下载资源

社区内提供随书附赠的资源，如书中的案例或程序源代码。

另外，社区还提供了大量的免费电子书，只要注册成为社区用户就可以免费下载。

与作译者互动

很多图书的作译者已经入驻社区，您可以关注他们，咨询技术问题；可以阅读不断更新的技术文章，听作译者和编辑畅聊好书背后有趣的故事；还可以参与社区的作者访谈栏目，向您关注的作者提出采访题目。

灵活优惠的购书

您可以方便地下单购买纸质图书或电子图书，纸质图书直接从人民邮电出版社书库发货，电子书提供多种阅读格式。

对于重磅新书，社区提供预售和新书首发服务，用户可以第一时间买到心仪的新书。

用户帐户中的积分可以用于购书优惠。100积分=1元，购买图书时，在  里填入可使用的积分数值，即可扣减相应金额。


特别优惠

购买本电子书的读者专享**异步社区优惠券**。使用方法：注册成为社区用户，在下单购书时输入“**57AWG**”，然后点击“使用优惠码”，即可享受电子书8折优惠（本优惠券只可使用一

】次）。

纸电图书组合购买

社区独家提供纸质图书和电子书组合购买方式，价格优惠，一次购买，多种阅读选择。



软技能：代码之外的生存指南
[美]约翰 Z. 森梅兹 (John Z. Sonmez) (作者) 王小刚 (译者) 杨海玲 (责任编辑)
分享 6 推荐 想读 9.0K 阅读

这是一本真正从“人”（而非技术也非管理）的角度关注软件开发人员自身发展的书。书中论述的内容既涉及生活习惯，又包括思维方式，凸显技术中“人”的因素，全面讲解软件行业从业人员所需要知道的所有“软技能”。
本书聚焦于软件开发人员生活的方方面面，从揭秘面试的流程到精耕细作出一份杀手级简历，从创建大受欢迎的博客到打造你的个人品牌，从提高自己工作效率到与如何与“拖延症”做斗争，甚至包括如何投资不动产，如何关注自己的健康。
本书共分为职业篇、自我营销篇、学习篇、生产力篇、理财篇、健身篇、精神篇等七篇，概括了软件行业从业人员所需的“软技能”。

● 纸质版 ￥59.00 ￥46.02 (7.8 折)
● 电子版 ￥35.00
● 电子版 + 纸质版 ￥59.00

现在购买 下载PDF样章
配套文件下载

社区里还可以做什么？

提交勘误

您可以在图书页面下方提交勘误，每条勘误被确认后可以获得100积分。热心勘误的读者还有机会参与书稿的审校和翻译工作。

写作

社区提供基于Markdown的写作环境，喜欢写作的您可以在此一试身手，在社区里分享您的技术心得和读书体会，更可以体验自出版的乐趣，轻松实现出版的梦想。

如果成为社区认证作译者，还可以享受异步社区提供的作者专享特色服务。

会议活动早知道

您可以掌握IT圈的技术会议资讯，更有机会免费获赠大会门票。

加入异步

扫描任意二维码都能找到我们：



异步社区



微信订阅号



微信服务号



官方微博



QQ群: 368449889

社区网址: www.epubit.com.cn

官方微博: 异步社区

官方微博: @人邮异步社区, @人民邮电出版社-信息技术分社

投稿&咨询: contact@epubit.com.cn